



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

MIROSLAV KOVAČEC

**MODEL UČINKOVITOGA UPRAVLJANJA
PROIZVODNIM SUSTAVIMA**

DOKTORSKI RAD

Zagreb, 2015.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING AND NAVAL
ARCHITECTURE

MIROSLAV KOVAČEC

EFFICIENT MANAGEMENT MODEL OF PRODUCTION SYSTEMS

DOCTORAL THESIS

Zagreb, 2015.



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

MIROSLAV KOVAČEC

MODEL UČINKOVITOGA UPRAVLJANJA PROIZVODNIM SUSTAVIMA

DOKTORSKI RAD

Mentor:

Prof. dr. sc. Nedeljko Štefanić

Zagreb, 2015.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING AND NAVAL
ARCHITECTURE

MIROSLAV KOVAČEC

EFFICIENT MANAGEMENT MODEL OF PRODUCTION SYSTEMS

DOCTORAL THESIS

Supervisor:

Professor Nedeljko Štefanić, PhD

Zagreb, 2015.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK: 658.5

Ključne riječi: AHP metoda, implementacija, model,
odlučivanje, proizvodni sustavi, upravljanje, vitka
proizvodnja, zelena proizvodnja

Znanstveno područje: Tehničke znanosti

Znanstveno polje: Strojarsstvo

Institucija u kojoj je rad izrađen: Fakultet strojarstva i brodogradnje (FSB, Zagreb)

Mentor rada: Prof. dr. sc. Nedeljko Štefanić

Broj stranica: 214

Broj slika: 68

Broj tablica: 75

Broj korištenih bibliografskih jedinica: 87

Datum obrane: 21.07.2015.

Povjerenstvo: Dr. sc. Goran Đukić, izv. prof. (FSB, Zagreb)
Dr. sc. Nedeljko Štefanić, red prof. (FSB, Zagreb)
Dr. sc. Ivica Veža, red. prof. (Fakultet
elektrotehnike, strojarstva i brodogradnje, Split)

Institucija u kojoj je rad pohranjen: Fakultet strojarstva i brodogradnje,
Sveučilište u Zagrebu

ZAHVALA

Ovim putem želio bih zahvaliti svima koji su mi na bilo koji način pomogli da izradim ovu disertaciju.

Prije svega zahvaljujem svom mentoru prof. dr. sc. Nedeljku Štefaniću na stručnom vođenju, savjetima i pomoći tijekom izrade ovog doktorskog rada.

Posebno se zahvaljujem članovima Povjerenstva za ocjenu i obranu disertacije: izv. prof. dr. sc. Goranu Đukiću i prof. dr. sc. Ivici Veži na korisnim savjetima i sugestijama pri konačnom oblikovanju rada.

Želim zahvaliti i kolegama sa *Zavoda za industrijsko inženjerstvo*, koji su mi bili podrška i pomoć tijekom izrade rada. Posebno se zahvaljujem dr. sc. Hrvoju Cajneru na vrlo korisnim savjetima i pomoći oko statističke obrade podataka.

Jednako se tako želim zahvaliti i kolegama s *Katedre za preradu polimera i drva* na pristupu znanstvenim bazama podataka, a posebno dr. sc. Ani Pilipović na pomoći tijekom studiranja, na savjetima, trudu, raspravama i primjedbama pri rješavanju različitih problema.

Zahvaljujem se i Upravi poduzeća Elektro-Kontakt d.d., i to Predsjedniku Uprave Domagoju Matasiću i Članu Uprave Hrvoju Mršiću, na dopuštenju za upotrebu podataka vezanih uz obradu primjera iz prakse i verifikaciju izrađenog modela. Posebno se zahvaljujem rukovoditeljici odjela Održavanje i upravljanje okolišem Jasni Hlupić na trudu, pomoći i potpori oko prikupljanja podataka i opisa sustava vezanih uz proizvodnju toplinske energije iskorištavanjem otpadne topline kompresora. Također se zahvaljujem Rukovoditelju proizvodnih sistema i CIP-a Josi Matasiću na savjetima, raspravama i primjedbama pri verifikaciji izrađenog modela učinkovitoga upravljanja poduzećem.

Toplo zahvaljujem akademiku Augustu Kovačecu na lekturi teksta.

Najviše se želim zahvaliti svojim roditeljima Mirku i Biserki te sestri Vesni na razumijevanju, strpljenju i bezrezervnoj potpori koju sam imao svih ovih godina.

IZJAVA

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija na Fakultetu te stručnu literaturu.

SADRŽAJ

PREDGOVOR	i
SAŽETAK	ii
KLJUČNE RIJEČI	ii
SUMMARY	iii
KEYWORDS	iii
POPIS SLIKA	iv
POPIS TABLICA	vii
POPIS OZNAKA	x
POPIS KRATICA	xii
1. UVOD	1
2. CILJ I HIPOTEZA RADA	2
3. PROIZVODNI SUSTAVI, UPRAVLJANJE I METRIKA PROIZVODNIH SUSTAVA	4
3.1. Povijesni razvoj proizvodnih sustava	4
3.2. Proizvodni sustav	8
3.2.1. Podjela proizvodnih sustava	10
3.3. Upravljanje proizvodnim sustavima	14
3.3.1. Vrste proizvodnje	15
3.3.2. Proizvodni menadžment	18
3.3.2.1. Ciljevi proizvodnoga menadžmenta	18
3.3.2.2. Aktivnosti proizvodnoga menadžmenta	19
3.4. Metrika proizvodnih sustava	21
3.4.1. Pokazatelji učinkovitosti proizvodnih sustava	21
3.4.2. Pokazatelji konkurentnosti proizvodnih sustava	24
3.4.3. Kontinuirano praćenje učinkovitosti proizvodnih sustava	25
4. SUVREMENE TEHNIKE I ALATI UČINKOVITOGA UPRAVLJANJA PROIZVODNIM SUSTAVIMA / PODUZEĆIMA	28
4.1. Šest sigma (e. <i>Six Sigma</i> - 6σ)	29
4.2. Re-inženjering poslovnih procesa (e. <i>Business Process Re-engineering</i> – <i>BPR</i>)	32
4.3. Uravnotežene kartice rezultata (e. <i>Balanced Scorecard</i> – <i>BSC</i>)	34
4.4. Cjelovito produktivno održavanje (e. <i>Total Productive Maintenance</i> – <i>TPM</i>)	36
4.5. Potpuno upravljanje kvalitetom (e. <i>Total Quality Management</i> – <i>TQM</i>)	38
4.6. 20 ključeva (e. <i>20 keys</i>)	40

4.7.	Vitka proizvodnja (e. <i>Lean production</i>)	42
4.7.1.	Vrste gubitaka	44
4.7.2.	Alati i tehnike vitke proizvodnje	46
4.7.3.	Implementacija vitke proizvodnje	51
4.8.	Zelena proizvodnja (e. <i>Green production</i>)	52
4.8.1.	Vrste gubitaka zelene proizvodnje	54
4.8.2.	Implementacija zelene proizvodnje	56
5.	DOSADAŠNJE SPOZNAJE NA PODRUČJU UČINKOVITOGA UPRAVLJANJA PROIZVODNOM / PODUZEĆEM	58
5.1.	Spoznaje vezane uz primjenu tehnika i alata vitke i zelene proizvodnje	58
5.2.	Spoznaje vezane uz primjenu metoda višekriterijskih analiza	62
5.2.1.	Primjena AHP metode kod implementacije vitkih alata	64
6.	ISTRAŽIVANJE O UPRAVLJANJU PODUZEĆIMA U RH	65
6.1.	Strukturno-poslovni pokazatelji poduzeća u RH	65
6.2.	Prikupljanje podataka	70
6.2.1.	Sadržaj ankete	71
6.2.2.	Ciljane grupe sudionika istraživanja i način prikupljanja podataka	74
6.3.	Analiza prikupljenih podataka	76
6.3.1.	Opće informacije o ispitanicima	77
6.3.1.1.	Klasifikacija prema veličini poduzeća	77
6.3.1.2.	Klasifikacija prema djelatnosti poduzeća	80
6.3.1.3.	Klasifikacija prema sudionicima istraživanja	81
6.3.2.	Analiza rezultata provedenog istraživanja prema anketnim pitanjima	83
6.3.2.1.	Testiranje razumijevanja vitke filozofije (anketna pitanja: 1., 2. i 3.)	83
6.3.2.2.	Komunikacija kod provedbe projekata (anketna pitanja: 4. i 5.)	90
6.3.2.3.	Primjena alata i tehnika vitke metodologije (anketno pitanje: 6.)	94
6.3.2.4.	Potencijali za smanjenje gubitaka u poduzeću (anketno pitanje: 7.)	98
7.	ANALIZA ZNATNOSTI UTJECAJA POKAZATELJA PODUZEĆA	103
7.1.	Primjena alata i tehnika vitke metodologije u hrvatskim poduzećima	104
7.1.1.	Analiza prema veličini poduzeća	104
7.1.2.	Analiza prema djelatnosti poduzeća	106
7.1.3.	Analiza prema radnom mjestu sudionika istraživanja	107
7.2.	Potencijal smanjenja gubitaka u poslovanju hrvatskih poduzeća	109
7.2.1.	Analiza prema veličini poduzeća	109
7.2.2.	Analiza prema djelatnosti poduzeća	113

7.2.3.	Analiza prema radnom mjestu sudionika istraživanja	114
8.	EVALUACIJA POGODNOSTI PRIMJENE VITKIH ALATA PREMA POKAZATELJIMA PODUZEĆA	117
8.1.	Analitički hijerarhijski proces (e. <i>Analitic Hierarchy Process – AHP</i>)	117
8.1.1.	Izrada hijerarhijske strukture problema odlučivanja	118
8.1.2.	Usporedba elemenata hijerarhijske strukture u parovima	119
8.1.3.	Izračun lokalnih prioriteta kriterija, potkriterija i alternativa	119
8.1.3.1.	Metoda svojstvenog vektora (e. <i>Eigenvectors methods</i>)	120
8.1.3.2.	Konzistentnost procjena	121
8.1.4.	Određivanje konačnog rješenja	122
8.2.	Evaluacija pogodnosti primjene vitkih alata za proizvodna mikropoduzeća	122
8.2.1.	Izrada hijerarhijske strukture	122
8.2.2.	Usporedba elemenata hijerarhijske strukture u parovima	125
8.2.2.1.	Usporedba kriterija (potkriterija) u parovima	125
8.2.2.2.	Usporedba alternativa (vitkih alata) u parovima	127
8.2.3.	Izračun prioriteta	127
8.2.3.1.	Izračun prioriteta kriterija i potkriterija	127
8.2.3.2.	Izračun prioriteta alternativa	132
8.2.4.	Određivanje konačnog rješenja	135
8.3.	Evaluacija pogodnosti primjene vitkih alata za proizvodna mala, srednje velika i velika poduzeća	136
8.3.1.	Hijerarhijska struktura problema	137
8.3.2.	Izračun prioriteta	138
8.3.3.	Konačno rješenje	139
8.4.	Evaluacija pogodnosti primjene vitkih alata za uslužna mikropoduzeća	140
8.4.1.	Hijerarhijska struktura problema	141
8.4.2.	Izračun prioriteta	142
8.4.3.	Konačno rješenje	143
8.5.	Evaluacija pogodnosti primjene vitkih alata za uslužna mala, srednje velika i velika poduzeća	144
8.5.1.	Hijerarhijska struktura problema	145
8.5.2.	Izračun prioriteta	146
8.5.3.	Konačno rješenje	147
9.	MODEL UČINKOVITOGA UPRAVLJANJA PODUZEĆEM	149
9.1.	Čimbenici odabira vitkih alata	149
9.1.1.	Potencijal smanjenja gubitaka u poslovanju poduzeća	151

9.1.2.	Financijski čimbenici implementacije vitkih alata	152
9.1.2.1.	Usporedba alternativa (vitkih alata) u parovima	153
9.1.2.2.	Izračun prioriteta alternativa	154
9.1.3.	Organizacijski čimbenici implementacije vitkih alata	155
9.1.3.1.	Usporedba alternativa (vitkih alata) u parovima	155
9.1.3.2.	Izračun prioriteta alternativa	156
9.2.	Opći model učinkovitoga upravljanja poduzećem	157
9.2.1.	Model učinkovitoga upravljanja proizvodnim mikropoduzećima	160
9.2.2.	Model učinkovitoga upravljanja proizvodnim malim, srednje velikim i velikim poduzećima	161
9.2.3.	Model učinkovitoga upravljanja uslužnim mikropoduzećima	162
9.2.4.	Model učinkovitoga upravljanja uslužnim malim, srednje velikim i velikim poduzećima	163
10.	VERIFIKACIJA MODELA I OBRADA PRIMJERA IZ PRAKSE	164
10.1.	O poduzeću Elektro-Kontakt d.d.	164
10.2.	Model učinkovitoga upravljanja	165
10.2.1.	Vektor prioriteta vrhovnog menadžmenta	165
10.2.1.1.	Množenje matrice usporedbe	166
10.2.1.2.	Određivanje 1. vektora prioriteta	167
10.2.1.3.	Množenje matrice usporedbe	167
10.2.1.4.	Određivanje 2. vektora prioriteta	168
10.2.1.5.	Izračunavanje konzistentnosti	169
10.2.2.	Vektor prioriteta vitkih alata za proizvodno veliko poduzeće Elektro-Kontakt d.d.	169
10.2.3.	Verifikacija modela	171
10.3.	Konkretni podaci primjene vitke i zelene proizvodnje	173
10.3.1.	Potencijal za postizanje ušteda	174
10.3.2.	Dnevne potrebe energije za grijanje potrošne tople vode (PTV-a)	174
10.3.3.	Energija dobivena iz kompresora K3 i K4 na godišnjoj razini	176
10.3.4.	Moguće iskorištavanje otpadne topline za zagrijavanje PTV-a i predgrijavanje za sustav radijatorskog kruga grijanja	177
10.3.5.	Izračun financijskih ušteda i smanjenja emisije CO ₂	177
10.3.6.	Provedba predloženih mjera	178
11.	ANALIZA REZULTATA	181
11.1.	Analiza provedenog istraživanja o upravljanju poduzećima u RH	181
11.2.	Analiza provedenih istraživanja o važnosti utjecaja pokazatelja poduzeća	182

11.3.	Analiza evaluacije vitkih alata	183
11.4.	Analiza modela učinkovitoga upravljanja poduzećima	184
11.5.	Smjerovi budućih istraživanja	185
12.	ZAKLJUČAK	186
13.	LITERATURA	188
14.	PRILOZI	194
	ŽIVOTOPIS	213
	BIOGRAPHY	214

PREDGOVOR

Visoki zahtjevi tržišta, velika konkurencija na globalnoj razini, sve zahtjevniji kupci i brzi tempo promjena u tehnologiji dovode do čestih promjena organizacijskih struktura i strateških ciljeva poduzeća. Ako ona žele opstati i izboriti se za svoj dio tržišta, poduzeća moraju pokazati veliku sposobnost prilagodbe na promjene koje im nameće tržište.

Iz strukturno-poslovnih pokazatelja poduzeća iz Republike Hrvatske vidi se da mnoga hrvatska poduzeća gube korak s konkurencijom, te gube tržište i propadaju. Nameće se potreba za prihvaćanjem novih znanja i tehnologija implementacijom suvremenih alata i tehnika upravljanja poduzećima koje se temelje na smanjenju rasipanja resursa, smanjenju nastanka otpada i smanjenju nepotrebnih aktivnosti, kako bi se spriječio ovaj negativan trend.

Analizom dostupne literature utvrđeno je da metode vezane uz učinkovito upravljanje proizvodnim sustavima (poduzećima) koje su razvijene u drugim državama nije moguće jednostavno preslikati na područje RH. Stoga je temeljni poticaj u pisanju doktorskog rada bila izrada modela učinkovitoga upravljanja proizvodnim sustavima koji se temelji na suvremenim tehnikama i alatima učinkovitoga upravljanja, primjenjujući spoznaje o poduzećima u Republici Hrvatskoj, čime se dobiva primjenjiv model za uspješnu implementaciju u hrvatska poduzeća.

U prvom dijelu rada prikazan je kratki povijesni razvoj proizvodnih sustava, zatim su ukratko opisane suvremene tehnike i alati upravljanja proizvodnim sustavima, te detaljnije obrađene: vitka proizvodnja (e. *Lean Production –LP*) i zelena proizvodnja (e. *Green Production - GP*). U drugom dijelu rada izrađena je anketa radi prikupljanja podataka o upravljanju hrvatskim poduzećima. Na osnovi obrađenih podataka prikupljenih anketom i spoznajama dobivenima iz literature izrađen je model učinkovitoga upravljanja proizvodnim sustavom, te opći model učinkovitoga upravljanja poduzećem u RH. Na kraju je izrađeni model učinkovitoga upravljanja proizvodnim sustavom testiran na primjeru upravljanja sustavom grijanja (proizvodnji toplinske energije).

Krapina, svibanj 2015.

Miroslav Kovačec, dipl. ing. stroj.

SAŽETAK

U današnjem konkurentnom okruženju vidljivo je da je prošlo doba velikih serija, te da mogu opstati samo prilagodljiva, tj. fleksibilna poduzeća. Na tržištu je velika konkurencija, što zahtijeva od poduzeća svakodnevne promjena u planiranju proizvodnje ili usluga. Bez obzira na to radi li se o proizvodnji robe ili pružanju usluga, rukovodstvo poduzeća mora osigurati postizanje i poštivanje konačnog cilja, a to je: proizvoditi kvalitetan proizvod, odnosno pružiti uslugu u pravo vrijeme, u traženoj količini, uz najmanje troškove. Suvremene tehnike i alati upravljanja poduzećem temeljeni na smanjenju rasipanja resursa i nastanka otpada dovode do smanjenja nepotrebnih aktivnosti, dok je kontinuirani rast poduzeća moguć samo kroz prihvaćanje novih znanja i tehnologija, a to uključuje i suvremene alate i tehnike upravljanja proizvodnim sustavima (poduzećima).

U suvremene alate i tehnike upravljanja proizvodnim sustavima svakako se ubrajaju vitka proizvodnja (e. *Lean Production* - LP) i zelena proizvodnja (e. *Green Production* - GP), koje su detaljno obrađene u doktorskom radu. S pomoću ankete prikupljeni su podaci o upravljanju poduzećima u Republici Hrvatskoj. Analizirano je stanje na području upravljanja, razinama primjene vitke i zelene proizvodnje, te prepreke i mogućnosti šire primjene u poduzećima u RH. Zatim je na temelju sistematiziranih podataka dobivenih istraživanjem izrađen model učinkovitoga upravljanja proizvodnim sustavima, te opći model učinkovitoga upravljanja poduzećem. Izrađeni modeli temelje se na tehnikama i alatima vitke i zelene proizvodnje sa smjernicama za uspješnu implementaciju navedenih alata i tehnika u hrvatska poduzeća. Navedeni model učinkovitoga upravljanja proizvodnim sustavima testiran je na primjeru upravljanja sustavom grijanja (proizvodnjom toplinske energije), radi povećanja energetske učinkovitosti i smanjenja utjecaja na okoliš. Dobiveni rezultati potvrdili su opravdanost predloženog modela učinkovitoga upravljanja i mogućnost primjene u hrvatskim poduzećima.

KLJUČNE RIJEČI

AHP metoda, implementacija, model, odučivanje, proizvodni sustavi, upravljanje, vitka proizvodnja, zelena proizvodnja

SUMMARY

In today's competitive environment, it is evident that it has passed the era of big product series, and can only survive the companies that can adjust – flexible companies. The competition in the market is high, which leads to daily changes in the production planning and services. Top management of the company, regardless of whether it is manufacturing of the product or services, must ensure compliance and achieve the final goal which is produce a quality product at the right time at the lowest cost with the right quantity. Modern methods and models, based on the reduction of resources and minimization of waste leads to a reduction of unnecessary activity. The continuous growth of the company is possible only through the acquisition of new knowledge and technology, and that includes the modern methods and models of production systems.

Modern methods and models for managing of production systems certainly include lean production and green production, which are detailed elaborated in a doctoral thesis. Surveys are used to collect data about companies in the Republic of Croatia, followed by the analyses of the already mentioned models (Lean Production - LP and Green Production - GP) and their possible application to the market in the Republic of Croatia. Finally, based on the systematized data obtained by research, the efficient management model of production systems are made, along with the general model of efficient management of the company. Above mentioned model are applied to the practice - heat system management (heat production) in order to increase energy efficiency and reduce environmental impact. The results confirmed the justification of the proposed model of efficient management and the possibility of their application in Croatian companies.

KEYWORDS

AHP methods, decision making, green production, implementation, lean production, managing, model, production system

POPIS SLIKA

Slika 3.1. Važne aktivnosti koje su dovele do današnjih proizvodnih sustava [2]	5
Slika 3.2. Shematski prikaz proizvodnog sustava [1]	9
Slika 3.3. Blokdijagram serijskog proizvodnog sustava [17]	11
Slika 3.4. Serijski proizvodni sustav s kontrolom kvalitete proizvoda [17]	12
Slika 3.5. Serijski proizvodni sustav s dodatnom obradom [17]	12
Slika 3.6. Montažni proizvodni sustav: a.) s jednim spajanjem operacija, b.) s višestrukim spajanjem operacija [17]	13
Slika 3.7. Kompleksni proizvodni sustav [17]	13
Slika 3.8. Organizacijska piramida [18]	14
Slika 3.9. Vrste proizvodnje [1]	16
Slika 3.10. Funkcije menadžmenta [18]	19
Slika 3.11. Povezanost produktivnosti, efikasnosti i učinkovitosti proizvodnog sustava [2]	22
Slika 4.1. DMAIC metoda [26]	31
Slika 4.2. Re-inženjering poslovnog procesa [28]	32
Slika 4.3. Uravnotežene kartice rezultata [31]	35
Slika 4.4. Tradicionalni TPM model [36]	36
Slika 4.5. PDCA krug [5]	39
Slika 4.6. 20 ključeva za poboljšanje procesa [41]	40
Slika 4.7. Radar-grafikon [41]	42
Slika 4.8. Principi vitkog menadžmenta [45]	43
Slika 4.9. Održivi razvoj [43]	53
Slika 4.10. LG ekološki dizajn [43]	56
Slika 6.1. Odabrani strukturno-poslovni pokazatelji nefinancijskog poslovnog gospodarstva u razdoblju od 2008. do 2012. [73]	68
Slika 6.2. Stopa rasta odabranih strukturno-poslovnih pokazatelja nefinancijskog poslovnog gospodarstva u 2012. (u odnosu na 2008.) [73]	69
Slika 6.3. Sadržaj ankete	72
Slika 6.4. Broj i udio ukupno prikupljenih anketa ovisno o načinu prikupljanja podataka	75
Slika 6.5. Broj i udio ispunjenih anketa ovisno o načinu prikupljanja podataka	77
Slika 6.6. Broj i udjeli poduzeća prema veličini poduzeća	78
Slika 6.7. Udjeli prema veličini poduzeća u 2012. (podaci DZS) [73]	79
Slika 6.8. Broj i udjeli poduzeća prema djelatnosti poduzeća	81
Slika 6.9. Klasifikacija prema sudionicima istraživanja	82

Slika 6.10. Asocijacije s vitkom filozofijom: a.) hrvatska poduzeća, b.) inozemna poduzeća [11]	83
Slika 6.11. Utjecaj na uspješnost poduzeća	86
Slika 6.12. Utjecaj na uspješnost poduzeća: a.) hrvatska poduzeća, b.) inozemna poduzeća [68]	87
Slika 6.13. Razlozi investiranja u povećanje učinkovitosti poslovanja poduzeća radi: a.) hrvatska poduzeća, b.) inozemna poduzeća [11]	89
Slika 6.14. Ovisnost poduzeća o dobavljačima (kooperantima)	91
Slika 6.15. Način komunikacije s dobavljačima (kooperantima)	91
Slika 6.16. Komunikacija kod provedbe projekta: a.) hrvatska poduzeća, b.) inozemna poduzeća [68]	93
Slika 6.17. Primjena specifičnih alata u poduzeću radi postizanja učinkovitijeg poduzeća: a.) hrvatska poduzeća, b.) inozemna poduzeća [11]	95
Slika 6.18. Postotak nedobivenih odgovora prema vrstama gubitaka prema LEAN metodologiji	98
Slika 6.19. Potencijal smanjenja gubitaka: prekomjerne proizvodnje, zaliha, transporta, čekanja	100
Slika 6.20. Potencijal smanjenja gubitaka: nepotrebnih kretanja, škarta, prekomjerne obrade, nedovoljnog korištenja potencijala radnika	101
Slika 7.1. "Boxplot" – prekomjerna proizvodnja – veličina poduzeća	110
Slika 7.2. "Boxplot" – zalihe – veličina poduzeća	111
Slika 7.3. "Boxplot" – transport – veličina poduzeća	111
Slika 7.4. "Boxplot" – nepotrebna kretanja – veličina poduzeća	112
Slika 7.5. "Boxplot" – prekomjerna proizvodnja – radno mjesto sudionika istraživanja	115
Slika 8.1. Hijerarhijski prikaz strukturiranja problema	118
Slika 8.2. Hijerarhijska struktura problema	123
Slika 8.3. AHP rang lista vitkih alata – proizvodna mikropoduzeća – prosječni potencijali po kriterijima i potkriterijima	126
Slika 8.4. AHP rang lista vitkih alata – proizvodna mikropoduzeća – lokalni prioritet kriterija i prosječni potencijali prema potkriterijima	129
Slika 8.5. AHP rang lista vitkih alata – proizvodna mikropoduzeća – lokalni prioriteti kriterija i potkriterija	130
Slika 8.6. AHP rang lista vitkih alata – proizvodna mikropoduzeća – globalni prioritet kriterija i potkriterija	131
Slika 8.7. <i>Pareto dijagram</i> vitkih alata za proizvodna mikropoduzeća	136
Slika 8.8. AHP rang lista vitkih alata – proizvodna mala, srednje velika i velika poduzeća – prosječni potencijali prema kriterijima i potkriterijima	137
Slika 8.9. <i>Pareto dijagram</i> vitkih alata za proizvodna mala, srednje velika i velika poduzeća	140

Slika 8.10. AHP rang lista vitkih alata – uslužna mikropoduzeća– prosječni potencijali prema kriterijima i potkriterijima	141
Slika 8.11. <i>Pareto dijagram</i> vitkih alata za uslužna mikropoduzeća	144
Slika 8.12. AHP rang lista vitkih alata – uslužna mala, srednje velika i velika poduzeća – prosječni potencijali prema kriterijima i potkriterijima	145
Slika 8.13. <i>Pareto dijagram</i> vitkih alata za uslužna mala, srednje velika i velika poduzeća	148
Slika 9.1. Najvažniji čimbenici odabira vitkog alata	151
Slika 9.2. <i>Pareto dijagram</i> vitkih alata prema financijskom čimbeniku od manjeg prema većem	154
Slika 9.3. <i>Pareto dijagram</i> vitkih alata prema organizacijskom čimbeniku od manjih prema većima	157
Slika 10.1. Prikaz usporedbi na <i>Saatyjevoj skali</i>	166
Slika 10.2. <i>Pareto dijagram</i> vitkih alata za proizvodno veliko poduzeće (Elektro-Kontakt d.d.).	170
Slika 10.3. Dispozicija zgrada kompleksa Elektro-Kontakt d.d. [86]	173
Slika 10.4. Shematski prikaz izvedenog stanja [88]	179
Slika 10.5. Detalj shematskog prikaza izvedenog stanja pripreme potrošne tople vode [88]	179
Slika 10.6. Detalj shematskog prikaza izvedenog stanja predgrijavanja ogrjevnog medija sustava radijatorskog grijanja [88]	180

POPIS TABLICA

Tablica 3.1. Povijesni pregled proizvodnog menadžmenta [1]	6
Tablica 3.2. Prednosti i nedostaci/ograničenja prema vrstama proizvodnje [1]	17
Tablica 3.3. Ciljevi poslovanja, objašnjenje i pokazatelji [2]	25
Tablica 4.1. Suvremene tehnike i alati učinkovitoga upravljanja [5]	28
Tablica 4.2. Definiranje sigma razine [25]	30
Tablica 4.3. Značenje i ciljevi 20 ključeva [42]	41
Tablica 4.4. Vrste gubitaka prema vitkoj metodologiji, opis i protumjera (vitki alat) [36]	44
Tablica 4.5. Temeljni alati i tehnike vitke metodologije [36]	46
Tablica 4.6. Ekološki utjecaj na tipove rasipanja u proizvodnji [45]	55
Tablica 6.1. Broj i udjeli poduzeća prema veličini poduzeća u razdoblju od 2008. do 2012. [73]	66
Tablica 6.2. Broj i udjeli zaposlenih osoba prema veličini poduzeća u razdoblju od 2010. do 2012. [73]	66
Tablica 6.3. Odabrani strukturno-poslovni pokazatelji nefinancijskog poslovnog gospodarstva u razdoblju od 2008. do 2012. [73]	68
Tablica 6.4. Broj prikupljenih anketa	75
Tablica 6.5. Ispunjenost prikupljenih anketa	76
Tablica 6.6. Broj poduzeća prema veličini poduzeća	79
Tablica 6.7. Odabrane djelatnosti nefinancijskog poslovnog gospodarstva RH [73]	80
Tablica 6.8. Test proporcija uzoraka – asocijacije s vitkom filozofijom	85
Tablica 6.9. Test proporcija uzoraka – utjecaj na uspješnost poduzeća	88
Tablica 6.10. Test proporcija uzoraka – razlozi investiranja u povećanje učinkovitosti poduzeća radi	90
Tablica 6.11. Test frekvencija uzoraka – komunikacija kod provedbe projekata	94
Tablica 6.12. Test frekvencija uzoraka – primjena specifičnih alata u poduzeću radi postizanja učinkovitijeg poduzeća	97
Tablica 7.1. <i>Kruskal-Wallis test</i> – primjena vitkih alata – analiza prema veličini poduzeća	105
Tablica 7.2. <i>Medijan test</i> – primjena vitkih alata – analiza prema veličini poduzeća	105
Tablica 7.3. <i>Mann-Whitney U test</i> – primjena vitkih alata – analiza prema djelatnosti poduzeća	107
Tablica 7.4. <i>Kruskal-Wallis test</i> – primjena vitkih alata – analiza prema radnom mjestu sudionika istraživanja	108
Tablica 7.5. <i>Medijan test</i> – primjena vitkih alata – analiza prema radnom mjestu sudionika istraživanja	108

Tablica 7.6. <i>Kruskal-Wallis test</i> – potencijal smanjenja gubitaka – analiza prema veličini poduzeća	109
Tablica 7.7. <i>Medijan test</i> – potencijal smanjenja gubitaka – analiza prema veličini poduzeća	110
Tablica 7.8. <i>Mann-Whitneyev U test</i> – potencijal smanjenja gubitaka – analiza prema djelatnosti poduzeća	113
Tablica 7.9. <i>Kruskal-Wallisov test</i> – potencijal smanjenja gubitaka – analiza prema radnom mjestu sudionika istraživanja	114
Tablica 7.10. <i>Medijan test</i> – potencijal smanjenja gubitaka – analiza prema radnom mjestu sudionika istraživanja	115
Tablica 8.1. <i>Saatyjeva skala</i> prioriteta [80]	119
Tablica 8.2. Vrijednost <i>RI</i> slučajnih indeksa [84]	121
Tablica 8.3. Potkriteriji	124
Tablica 8.4. Alternative	124
Tablica 8.5. Matrica usporedbe alternativa prema potkriteriju 1. d)	127
Tablica 8.6. Izračun lokalnih prioriteta kriterija	128
Tablica 8.7. Izračun lokalnog prioriteta potkriterija	128
Tablica 8.8. Prioriteti alternativa prema kriterijima	133
Tablica 9.1. Ponderi kritičnih čimbenika uspješnosti [72]	150
Tablica 9.2. Matrica usporedbe alternativa prema kriteriju financijski čimbenik	153
Tablica 9.3. Matrica usporedbe alternativa prema kriteriju organizacijski čimbenik	156
Tablica 10.1. Matrica usporedbe	166
Tablica 10.2. Matrica usporedbe nakon prvog množenja	167
Tablica 10.3. Matrica usporedbe nakon drugog množenja	168
Tablica 10.4. Instalirani kompresori [85]	174
Tablica 10.5. Energija potrebna za zagrijavanje PTV-a [85]	175
Tablica 10.6. Snage kompresora K3 i K4 [85]	176
Tablica 10.7. Snage izmjenjivača, radni sati kompresora i toplinska energija iz kompresora	176
Tablica 10.8. Energija iz kompresora [85]	177
Tablica 10.9. Financijske uštede na toplinskoj energiji [86]	178
Tablica 11.1. Rang liste vitkih alata prema pokazateljima poduzeća	184
Tablica 14.1. Matrica usporedbe alternativa prema potkriteriju 1. a)	201
Tablica 14.2. Matrica usporedbe alternativa prema potkriteriju 1. b)	201
Tablica 14.3. Matrica usporedbe alternativa prema potkriteriju 1. c)	202
Tablica 14.4. Matrica usporedbe alternativa prema potkriteriju 1. d)	202
Tablica 14.5. Matrica usporedbe alternativa prema potkriteriju 2. a)	203

Tablica 14.6. Matrica usporedbe alternativa prema potkriteriju 2. b)	203
Tablica 14.7. Matrica usporedbe alternativa prema potkriteriju 3. a)	204
Tablica 14.8. Matrica usporedbe alternativa prema potkriteriju 3. b)	204
Tablica 14.9. Matrica usporedbe alternativa prema potkriteriju 3. c)	205
Tablica 14.10. Matrica usporedbe alternativa prema potkriteriju 4. a)	205
Tablica 14.11. Matrica usporedbe alternativa prema potkriteriju 4. b)	206
Tablica 14.12. Matrica usporedbe alternativa prema potkriteriju 4. c)	206
Tablica 14.13. Matrica usporedbe alternativa prema potkriteriju 4. d)	207
Tablica 14.14. Matrica usporedbe alternativa prema potkriteriju 5. a)	207
Tablica 14.15. Matrica usporedbe alternativa prema potkriteriju 5. b)	208
Tablica 14.16. Matrica usporedbe alternativa prema potkriteriju 5. c)	208
Tablica 14.17. Matrica usporedbe alternativa prema kriteriju 6. a)	209
Tablica 14.18. Matrica usporedbe alternativa prema potkriteriju 7. a)	209
Tablica 14.19. Matrica usporedbe alternativa prema potkriteriju 7. b)	210
Tablica 14.20. Matrica usporedbe alternativa prema potkriteriju 7. c)	210
Tablica 14.21. Matrica usporedbe alternativa prema potkriteriju 7. d)	211
Tablica 14.22. Matrica usporedbe alternativa prema potkriteriju 8. a)	211
Tablica 14.23. Matrica usporedbe alternativa prema potkriteriju 8. b)	212

POPIS OZNAKA

Oznaka	Jedinica	Značenje oznake
A		matrica usporedbe
AD	kWh / god	količina potrošene toplinske energije
b_i		uređaj za rukovanje materijalom
c	J / kgK	specifični toplinski kapacitet
CI		indeks konzistentnosti
CR		omjer konzistentnosti
EF	kg CO ₂ / kWh	specifični koeficijent emisije CO ₂ za toplinsku energiju
EM	kg /god	emisije CO ₂
f		funkcija proizvodnog sustava
m	kg	masa
MAE	%	učinkovitost ručne montaže
m_i		proizvodna jedinica
m_{Ni}		stroj koji može proizvesti neispravan dio
n		broj redova matrice
N		broj sastavljenih jedinica
N_A		broj montera
OEE	%	ukupna učinkovitost opreme
p		vjerojatnost odbacivanja nulte hipoteze
P	%	produktivnost
Q	kWh	toplinska energija
r_i		inspekcijski uređaj
RI		slučajni indeks konzistentnosti
T	K	termodinamička temperatura
t_{lai}	s, min, h	idealno vrijeme za montažu jedne jedinice
t_{PS}	s, min, h	ukupno planirano vrijeme zaustavljanja
t_{Ri}	s, min, h	vrijeme dodatne obrade nakon procesa montaže jedinice
t_{tot}	s, min, h	ukupno vrijeme
t_{TOT}	s, min, h	ukupno raspoloživo vrijeme
t_{UN}	s, min, h	ukupno neiskorišteno vrijeme montaže

t_{va}	s, min, h	vrijeme dodavanja vrijednosti
w		vektor prioriteta
X_{kf}		kontrolirani faktori
X_{nf}		nekontrolirani faktori (poremećaji)
X_u		ulazi (faktori, varijable)
Y_i		izlazna veličina
λ_{max}		maksimalna vrijednost matrice

POPIS KRATICA

Kratika	Opis
6σ	šest sigma (e. <i>Six Sigma</i>)
AHP	analitički hijerarhijski process (e. <i>Analytic Hierarchy Process</i>)
BPR	re-inženjering poslovnih procesa (e. <i>Business Process Reengineering</i>)
BSC	uravnotežene kartice rezultata (e. <i>Balanced Scorecard</i>)
CIP	kontinuirani proces poboljšanja (e. <i>Continuous Improvement Process</i>)
DZS	državni zavod za statistiku
GP	zelena proizvodnja (e. <i>Green Production</i>)
JIT	proizvodnja u pravo vrijeme (e. <i>Just-In-Time Production</i>)
KPI	ključni indikatori performance (e. <i>Key Performance Indicator</i>)
LP	vitka proizvodnja (e. <i>Lean Production</i>)
MAE	učinkovitost ručne montaže (e. <i>manual assembly efficiency</i>)
NKD	nacionalna klasifikacija djelatnosti
OEE	ukupna učinkovitost opreme (e. <i>overall equipment effectiveness</i>)
PDCA	planiraj-izvedi-provjeri-postupaj (e. <i>Plan-Do-Check-Act</i>)
PPORF	praktični program revolucije u tvornicama (e. <i>The Practical Programme of Revolution in Factories</i>)
PTV	potrošna topla voda
QA	osiguranje kvalitete (e. <i>quality assurance</i>)
QC	kontrole kvalitete (e. <i>quality control</i>)
SEM	strukturalno modeliranje (e. <i>Structural Equation Modeling</i>)
SMED	brza izmjena alata (e. <i>Single Minute Exchange of Dies</i>)
SMP	srednja i mala poduzeća (podrazumijevaju srednja, mala i mikropoduzeća)
TPM	cjelovito produktivno održavanje (e. <i>Total Productive Maintenance</i>)
TPS	Toyotin proizvodni sustav (e. <i>Toyota production system</i>)
TQM	potpuno upravljanje kvalitetom (e. <i>Total Quality Management</i>)
VSD	promjenljiv broj okretaja (e. <i>Variable Speed Drive</i>)

1. UVOD

Način upravljanja poduzećem izravno utječe na uspješnost poduzeća. Zbog velike konkurencije na tržištu, poduzeća koja žele poboljšati svoju poziciju moraju se nositi sa stalnim promjenama i novim zahtjevima tržišta. Kontinuiranim unaprjeđenjem poslovnih procesa i fokusiranjem na kupce povećava se učinkovitost poduzeća. Time poduzeća postaju konkurentnija cijenom, kvalitetom i vremenom isporuke roba ili usluga, uz istodobno smanjenje troškova i gubitaka. Iz toga proizlazi potreba za upravljačkim sustavom koji uravnotežuje financijske podatke sa svakodnevnim pokretačima poslovnog uspjeha tako da tvrtki omogućuje efikasno izvođenje poslovne strategije [1, 2, 3, 4].

Gospodarska kriza, potpomognuta velikom konkurencijom na globalnoj razini, dovela je do toga da mnoga hrvatska poduzeća gube tržište od fleksibilnijih poduzeća koja imaju veliku sposobnost prilagodbe na promjene koje im nameće tržište. Zbog toga je potrebno u hrvatska poduzeća implementirati neke od alata i tehnika učinkovitoga upravljanja. Na taj bi se način prepoznali glavni uzročno-posljedični odnosi koji karakteriziraju okolinu u kojoj djeluju te pronašli novi pristupi koji omogućuju bolju kontrolu proizvodnih sustava i učinkovitiju primjenu resursa poduzeća. [5]

Većina proizvodnih poduzeća u svijetu svoj razvoj i unaprjeđenje proizvodnih sustava temelje na primjeru Toyotina proizvodnog sustava (e. *Toyota production system - TPS*), na vitkoj (e. *Lean production - LP*) te zelenoj proizvodnji (e. *Green production - GP*)¹. Vitka i zelena proizvodnja opisane su u poglavljima 4.7 i 4.8. Glavni ciljevi tih alata i tehnika učinkovitoga upravljanja jesu: poboljšanje planiranja procesa, povećanje produktivnosti, smanjenje razine zaliha, poboljšanje reagiranja na promjene u potražnji, poboljšanje kvalitete uz niže troškove proizvodnje, smanjenje utjecaja na okoliš, itd. [6, 7]. Može se reći da poduzeća koja primjenjuju suvremene alate i tehnike upravljanja mogu postići i održavati potrebnu kvalitetu svog poslovanja te ostvariti konkurentnu prednost u vođenju i upravljanju poslovnim odnosima na koje utječu brze tehnološke promjene sa složenim međuodnosima između različitih gospodarskih sektora i tržišnih čimbenika [5].

¹ U literaturi se *TPS*, *LP*, *GP* pojavljuju pod različitim nazivima poput: metode i modeli, alati i tehnike, pristupi, koncepti.

2. CILJ I HIPOTEZA RADA

U odnosu na područje Republike Hrvatske (RH), suvremene tehnike i alati učinkovitoga upravljanja proizvodnjom (poduzećima) razvijene su u državama (Japan, SAD) u kojima postoje velike razlike u mentalitetu, načinu obrazovanja, osobnim ciljevima, socijalnoj strukturi, menadžerima, itd. te ih nije moguće jednostavno preslikati [8].

Razvijeno je mnogo tehnika i alata proizvodnih sustava, npr.: re-inženjering poslovnih procesa (e. *Business Process Reengineering - BPR*), proizvodnja u pravo vrijeme (e. *Just-In-Time Production - JIT*), neprekidni proces poboljšanja (e. *Continual Improvement Process - CIP*), brza izmjena alata (e. *Single Minute Exchange of Dies - SMED*²), cjelovito produktivno održavanje (e. *Total Productive Maintenance - TPM*³), potpuno upravljanje kvalitetom (e. *Total Quality Management - TQM*), vitka proizvodnja (e. *Lean Production - LP*), 20 ključeva (e. *20 keys*) i šest sigma (e. *Six Sigma - 6σ*).

Dosadašnje spoznaje drugih autora, vezane uz tehnike i alate učinkovitoga upravljanja proizvodnjom / poduzećem, na temelju kojih je izrađen model učinkovitoga upravljanja proizvodnim sustavima, opisana su u poglavlju 5.

Cilj je rada izrada modela učinkovitoga upravljanja proizvodnim sustavima koji se temelji na suvremenim alatima i tehnikama vitke proizvodnje (e. *Lean Production - LP*) i zelene proizvodnje (e. *Green Production - GP*) primjenjujući spoznaje o okruženju u Republici Hrvatskoj, čime se dobiva primjenljiv model za uspješnu implementaciju u hrvatska poduzeća. U navedenom modelu vitkom proizvodnjom utječe se na smanjenje gubitaka kao što su: prekomjerna proizvodnja, visoke zalihe, nepotrebna kretanja, škart, prekomjerna obrada, nedovoljna primjena potencijala radnika. Zelenom proizvodnjom utječe se na smanjenje prekomjerne primjene energije i štetnih emisija u okoliš, te povećava primjena materijala koji se mogu reciklirati. Na osnovi izrađenog modela učinkovitoga upravljanja proizvodnim sustavima izrađen je opći model učinkovitoga upravljanja poduzećem primjenljiv i na uslužna poduzeća.

² U literaturi se *SMED* pojavljuje pod različitim nazivima poput: brza promjena alata, brza izmjena alata, jednominutna zamjena alata.

³ U literaturi se *TPM* pojavljuje pod različitim nazivima poput: cjelovito produktivno održavanje, ukupno produktivno održavanje, ukupno održavanje proizvodnje.

Hipoteza rada izražena je pretpostavkom da se tako razvijeni model učinkovitoga upravljanja može uspješno primijeniti i u proizvodnim i u uslužnim poduzećima.

Izrađeni model učinkovitoga upravljanja proizvodnim sustavima testiran je na primjeru upravljanja sustavom grijanja (proizvodnjom toplinske energije) radi povećanja energetske učinkovitosti. Na osnovi izrađenog modela učinkovitoga upravljanja proizvodnim sustavima i općeg modela učinkovitoga upravljanja poduzećem u RH, uz obradu primjera upravljanja sustavom grijanja dan je kritički osvrt na dosadašnje spoznaje vezane uz učinkovito upravljanje i mogućnost njihove primjene u hrvatskim poduzećima.

Očekuje se da će se dobivenim znanjima i izrađenim modelima dati smjernice vodstvu poduzeća za uspješnu implementaciju izrađenih modela u hrvatska poduzeća, čime će se pridonijeti većoj fleksibilnosti i učinkovitosti, a samim time i konkurentnosti, uz istodobnu veću motivaciju i zadovoljstvo zaposlenika.

3. PROIZVODNI SUSTAVI, UPRAVLJANJE I METRIKA PROIZVODNIH SUSTAVA

U ovom poglavlju dan je pregled povijesnog razvoja proizvodnih sustava i onih povijesnih zbivanja koja su dovela do današnjih proizvodnih sustava. Također je navedeno nekoliko definicija proizvodnog sustava te kratki opis i karakteristike proizvodnih sustava. Također je navedena podjela proizvodnih sustava, a za svaku vrstu sustava navedene su karakteristike, prednosti i nedostaci. Opisano je upravljanje proizvodnim sustavima, proizvodni menadžment te ciljevi i aktivnosti proizvodnog menadžmenta. Na kraju poglavlja navedena je metrika proizvodnih sustava, odnosno pokazatelji koji se primjenjuju kod praćenja i analiza proizvodnih sustava. Izložena teorijska podloga u ovom poglavlju temelj je za praćenje i bolje razumijevanje sljedećih poglavlja.

3.1. Povijesni razvoj proizvodnih sustava

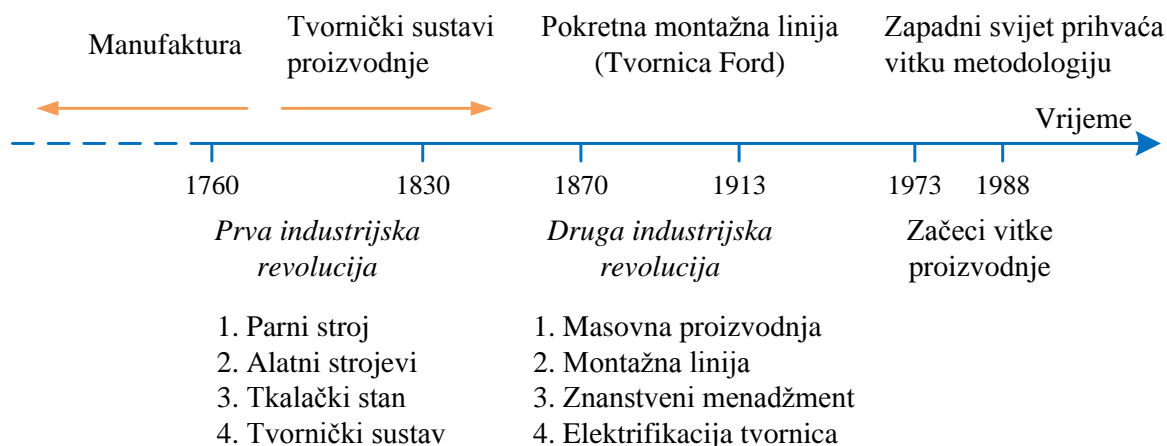
Tijekom industrijskog razvoja jedan od glavnih ciljeva bio je kako postići što bolje proizvodne rezultate. Od samih početaka, preko industrijskih revolucija u 19. i 20. stoljeću do danas, tijekom različitih razdoblja, dominirali su različiti načini proizvodnje, koji se na općoj razini mogu svrstati u obrtništvo, manufakturu, masovnu proizvodnju i vitku proizvodnju. [2]

Sam razvoj proizvodnih sustava tijekom vremena moguće je podijeliti u dvije osnovne grupe: [2]

1. Otkrića i izumi materijala i postupaka proizvodnje;
2. Razvoj proizvodnih sustava, odnosno različitih načina organizacije strojeva i ljudi tako da se učinkovitije provodi proizvodnja.

Materijali i postupci proizvodnje imaju jako dugu povijest. Postupci poput lijevanja, brušenja i kovanja datiraju od prije 6000 godina. Prve proizvodnje, primjerice oružja i oruđa nastale su obrtništvom, dok prvi pokušaji manufakturne proizvodnje potječu iz antičkog Rima. Rimljani su imali tzv. tvornice za proizvodnju oružja, keramike, stakla i ostalih proizvoda, iako su pritom bili upotrebljeni postupci koji se temelje na ručnom radu. Pravi razvoj prema današnjim proizvodnim sustavima započinje u 19. stoljeću kada su razvijeni tvornički sustavi

[2, 9]. Nekoliko povijesnih događaja i otkrića imalo je važan utjecaj na razvoj današnjih proizvodnih sustava koji su prikazani na slici 3.1. [2]



Slika 3.1. Važne aktivnosti koje su dovele do današnjih proizvodnih sustava [2]

Prva industrijska revolucija (1760 - 1830) imala je velik utjecaj na proizvodne sustave. Gospodarstvo koje se prije nje temeljilo uglavnom na poljoprivredi i obrtu počelo se temeljiti na industriji i proizvodnji. Tradicionalni pogled na upravljanje proizvodnjom započeo je kada je Adam Smith upozorio na ekonomske koristi od specijalizacije rada. Preporučio je podjelu rada, s ciljem da radnik postaje specijalist u svom poslu i obavlja svoje zadatke vrlo vješto i učinkovito. Izumom parnog stroja dobivena je nova snaga za pogon strojeva, a ona je zamijenila snagu vode, vjetra i životinja. Dolazi do velikog tehničkog razvoja u kojem se razina mehanizacije i automatizacije strojeva te opreme i alata jako povećala. Nastaju "tvornički sustavi" kod kojih se način organiziranja temelji na podjeli rada. [1, 2, 9, 10]

Sredinom i krajem 19. stoljeća (druga industrijska revolucija) dolazi do velike potrebe za željezom i čelikom, radi širenja željeznica, te za parnim brodovima i drugim strojevima. Kako bi se zadovoljile navedene potrebe razvile, su se nove metode i novi proizvodni sustavi poput masovne proizvodnje, montažne proizvodne linije i elektrifikacije tvornica. Usporedno s time, u ranom 20. stoljeću, Frederick W. Taylor provodi Smith-ove teorije i razvija znanstveni menadžment. U tom razdoblju razvijene su mnoge tehnike u kojima prevladava podjela rada na jednostavne zadatke. Kratke informacije o doprinosima proizvodnog menadžmenta prikazane su u tablici 3.1. [1, 10]

Tablica 3.1. Povijesni pregled proizvodnog menadžmenta [1]

Godina	Doprinos	Autor
1776	Specijalizacija rada u proizvodnji	Adam Smith
1799	Izmjenljivi dijelovi, evidencija troškova proizvodnje	Eli Whitney i ostali
1832	Podjela rada po vještinama; raspored poslova po vještinama; osnove studija rada	Charles Babbage
1900	Razvoj znanstvenog menadžmenta i studija rada	Frederick W. Taylor
1900	Analize radnih mjesta	Frank B. Gilbreth
1901	Planiranje zaposlenika i strojeva u proizvodnji	Henry L. Gantt
1915	Ekonomске veličine za upravljanje zalihama	F.W. Harris
1927	Ljudski odnosi	Elton Mayo
1931	Statistička obrada primijenjena na kvaliteti proizvoda; Dijagrami kontrole kvalitete	W.A. Shewart
1935	Statistička uzrokovanja primijenjena na kontroli kvalitete; pregled planova uzrokovanja	H.F. Dodge i H.G. Roming
1940	Operacijska istraživanja primijenjena u II. svjetskom ratu	P.M. Blacker
1946	Digitalna računala	John Mauchly i J.P. Eckert
1947	Linearno programiranje	G.B. Dantzig, Williams i ostali
1950	Matematičko programiranje na linearnim i stohastičkim procesima	A. Charnes, W.W. Cooper
1951	Poslovna digitalna računala; dostupni veliki izračuni	Sperry Univac
1960	Organizacijsko ponašanje	L. Summings, L. Porter
1970	Integracija operacija u cjelokupnu strategiju primjenom računalnih aplikacija u proizvodnji, planiranju i kontroli	W. Skinner, J. Orlicky i G. Wright
1980	Aplikacije za kvalitetu i produktivnost iz Japana; robotika, CAD-CAM	W.E. Deming i J. Juran

Strojevi omogućuju proizvodnju "identičnih" komponenti, što je preduvjet za masovnu proizvodnju, do koje je došlo u 20. stoljeću. To je također uzrokovalo poticanje daljnjeg tehničkog razvoja, što je povlačilo za sobom i kontinuirani razvoj opreme i alata. Uz povećan stupanj mehanizacije i automatizacije strojeva, njihovi su troškovi povećani, a samim time je korištenje kapaciteta stroja postao važan čimbenik za rad. Posljedice koje iz toga proizlaze

jesu potrebe za razvojem novih metoda u planiranju proizvodnje, za lancima opskrbe i informacija. [1, 2, 11]

Najbolji je primjer masovne proizvodnje početkom 20. stoljeća proizvodnja automobila *T Ford*. Henry Ford razvio je pokretnu montažnu proizvodnu liniju (traku), na kojoj su standardizirani dijelovi modela *T Ford* sklapani na vrlo učinkovitoj pokretnoj montažnoj liniji, čime je model *T Ford* postao relativno jeftin za izradu i gotovo svima cjenovno dostupan. Međutim, sama kvaliteta izrade bila je na niskoj razini, što je dovelo do učestalih kvarova, a jedan je od glavnih uzroka taj što radnici nisu bili uključeni u organizaciju rada i dio proizvodnog procesa, nego su samo izvršavali pojedine radnje. Prepoznata je važnost uključivanja radnika u organizaciju rada i proizvodni proces radi postizanja učinkovitih promjena, a to dovodi do razvoja proizvodnog menadžmenta. [2, 11, 12]

Proizvodni menadžment postaje prihvatljiv termin od 1930. do 1950. godine kada Taylor-ovi radovi o znanstvenom menadžmentu i studiju rada postaju široko poznati. U njima navodi da se učinkovitost proizvodnje može uvelike poboljšati detaljnim promatranjem radnika radi pronalaska i otklanjanja gubitaka u vremenu i kretanjama kod obavljanja pojedinih radnih zadataka (operacija). Uloga je menadžmenta odrediti najbolji način za obavljanje posla, utvrditi točnu razinu produktivnosti i postaviti nove radne norme koje se temelje na toj razini. [1, 2]

Sljedeća velika promjena proizvodne filozofije dogodila se u Japanu. Inženjer *Toyota Motor Company*, Eiji Toyoda, posjetio je 1950. godine jednu od Fordovih tvornica u Detroitu. Impresionirala ga je završna montažna linija (traka) na kojoj se montažni proces odvija u kontinuiranom, sinkroniziranom ritmu. Međutim, primijetio je da to vrijedi samo za montažnu liniju, dok su za ostale faze procesa proizvodnje dijelovi i materijali proizvedeni u velikim zasebnim serijama. Rezultat je ogromna količina zaliha posvuda u tvornici, veliki gubici kretanja materijala, zametnuti dijelovi i materijali, te je potreban velik trud da se sve to organizira. Nakon povratka u Japan, zajedno s proizvodnim menadžerom Taiichijem Ohnoom, zaključio je da na Fordovoj masovnoj proizvodnoj liniji ima mogućnosti za poboljšanje sustava proizvodnje. Stoga su razvijene metode i poboljšanja koja su dovele od izrade višenamjenske opreme, koja je pokretna i lako se prilagođava za proizvodnju različitih dijelova za različite proizvode. Time je omogućena sposobnost proizvodnje dijelova u malim

serijama, kada je potrebno, i sinkronizacija cijelog proizvodnog sustava, a ne samo završne montažne linije. [10, 12]

Koncept Toyotina proizvodnog sustava (TPS) temelji se na smanjenju vremena, od narudžbe kupaca do naplate proizvoda, kako bi se uklonile radnje koje ne dodaju vrijednost proizvodu. Navedenu proizvodnu filozofiju prihvatili su i ostali proizvođači diljem svijeta te implementiraju TPS alate u svoje postojeće proizvodne sustave. Iz Toyotina proizvodnog sustava, daljnjim "uklanjanjem gubitaka" u poslovanju poduzeća, razvijena je vitka proizvodnja. [10, 11, 12]

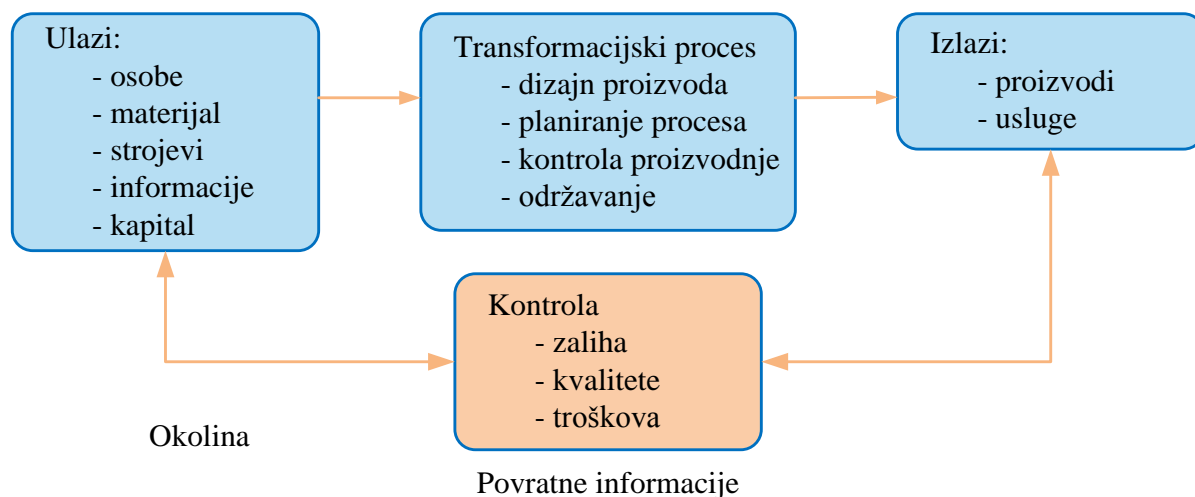
3.2. Proizvodni sustav

Proizvodni sustav rezultat je odabranih rješenja, koja se više ili manje temelje na savjesnim odlukama na koje svakako imaju utjecaj povijesna stečena saznanja, kao i ponuđene mogućnosti u smislu raznih tehničkih, organizacijskih i ekonomskih rješenja. [1, 2, 3]

U literaturi se navode definicije proizvodnih sustava poput: [1, 2, 3, 13, 14]

- Proizvodni sustav je složena socijalna i materijalna tvorevina kojom se obnaša proces stvaranja vrijednosti – materijalnih i drugih dobara.
- Proizvodni sustav je aktivnost u kojoj se resursi, točno određenim redoslijedom, kombiniraju i transformiraju na kontrolirani način uz dodavanje vrijednosti sve do krajnjeg proizvoda.
- Proizvodni sustav je dio organizacije koji se bavi transformacijom ulaznih veličina u željeni izlaz, proizvod ili uslugu, uz potrebnu razinu kvalitete.
- Proizvodni sustav može se definirati kao kombinacija ljudi, strojeva i opreme koji su međusobno povezani preko protoka materijala i informacija.
- Proizvodni sustav predstavlja transformaciju sirovina ili komponenti u gotove proizvode.

Na slici 3.2 shematski je prikazan proizvodni sustav, koji se sastoji od ulaznih veličina, proizvodnog (transformacijskog) procesa, izlaznih veličina i kontrole (povratne informacije).



Slika 3.2. Shematski prikaz proizvodnog sustava [1]

Također se vidi da je proizvodni sustav otvoreni sustav jer na njega utječe okruženje u kojem se nalazi pa cijelo vrijeme mora održavati dinamičan odnos s okolinom koja je neophodna za proizvodni sustav. Proizvodni sustav ima svoje vanjsko i unutarnje okruženje. Unutarnje okruženje čine službe unutar poduzeća: financije, računovodstvo, marketing, ljudski resursi, inženjering, proizvodnja i dr. Vanjsko okruženje čine dobavljači, kupci, konkurencija, sindikati i dr. Između vanjskog i unutarnjeg okruženja poželjno je razviti optimalne odnose koji se postižu povratnim informacijama, koje su nužne za kontrolu i poboljšanje učinkovitosti sustava. [1, 3]

Proizvodni sustav je: [1, 3]

- konkretan sustav s potpuno definiranim vezama između elemenata sustava
- umjetan, stvoren ljudskim radom, radi zadovoljavanja ljudskih potreba
- dinamičan, jer se stanje sustava mijenja tijekom vremena
- složen, jer se najčešće sastoji od više elemenata povezanih tokovima proizvodnje, od kojih svaki pojedinačno predstavlja složen zaseban (pod)sustav
- otvoren, neizoliran od utjecaja vanjskih sustava, posjedujući brojne veze sa svojim okruženjem
- stohastičan, jer se ponašanje proizvodnog sustava može predvidjeti samo s određenom vjerojatnošću (tržišne promjene)
- sociotehnički, jer su temeljni činitelji sustava ljudi i tehnička sredstva

Osim navedenog shematskog prikaza proizvodnog sustava na slici 3.2, u literaturi se često susrećemo s funkcijskim zapisom proizvodnog sustava. Proizvodni sustav moguće je prikazati pomoću matematičke jednadžbe u kojoj su izlazne veličine prikazane kao funkcija ulaznih veličina proizvodnog sustava. Broj izlaznih veličina koji se može postići s danim ulazima određen je stanjem tehnologije proizvodnog sustava [1, 15]. Funkcijski zapis proizvodnog sustava formuliran je izrazom:

$$Y_i = f(X_u, X_{kf}, X_{nf}) \quad (3.1)$$

gdje je Y_i – izlazna veličina, X_u – ulazi (faktori, varijable), X_{kf} – kontrolirani faktori, X_{nf} – nekontrolirani faktori (poremećaji).

3.2.1. Podjela proizvodnih sustava

Ovisno o svrsi opisa proizvodnih sustava primjenjuju se različite podjele sustava. U nastavku se navode neke od uobičajenih podjela proizvodnih sustava.

Proizvodni sustavi mogu se opisati iz funkcionalne, strukturne i hijerarhijske perspektive (Seliger i dr.) [2]. Proizvodni sustav iz funkcionalne perspektive opisuje se kao crna kutija koja pretvara ulaze u izlaze. Strukturna perspektiva je način opisivanja sustava u pogledu njegovih različitih elemenata i odnosa između tih elemenata sustava. Proizvodni sustav također se može razmatrati iz hijerarhijske perspektive, što implicira da sustav može biti podsustav unutar većeg sustava.

Drugi primjeri podjele proizvodnih sustava jesu: [2]

- realni i modelirani sustavi
- kontinuirani i diskretni sustavi
- stohastički i deterministički sustavi

Realni sustavi sastoje se od stvarnih objekata, kao što su strojevi i oprema, dok se modelirani sustavi sastoje od blok dijagrama, grafikona i sl. Modelirani sustavi primjenjuju se u fazi projektiranja proizvodnih sustava, koji postaju realni (fizički) proizvodni sustavi nakon faze provedbe. [2]


Kontinuirani i diskretni proizvodni sustavi spadaju u kategoriju dinamičkih sustava, koji se definiraju na temelju toga kako se varijable sustava mijenjaju tijekom vremena. U kontinuiranom sustavu varijable sustava mijenjaju se kontinuirano tijekom vremena, dok se u diskretnom sustavu mijenjaju korak po korak. [2]

Kod determinističkih proizvodnih sustava postoji jasna veza između ulaznih i izlaznih varijabli, odnosno za dani ulaz sustav uvijek daje isti izlaz. Stohastički proizvodni sustav karakteriziraju slučajna svojstva kod kojih se ulazne varijable, proces i izlazne varijable mogu jedino statistički analizirati. [2]

Vrlo često se u literaturi primjenjuje podjela proizvodnih sustava na: serijske, montažne i kompleksne proizvodne sustave, koji su detaljnije opisani u nastavku.

Serijski proizvodni sustav – tako se često naziva serijska proizvodna linija (traka) koju čini grupa proizvodnih jedinica raspoređenih u uzastopnom redu u kojima je rukovanje materijalom uređeno tako da je izlaz iz jedne proizvodne jedinice ulaz u drugu. Predmet obrade mijenja svoj oblik (ili druge osobine) od ulazne sirovine (jedne ili nekoliko), transformira se u neki od materijala, poluproizvoda sve do finalnog proizvoda. [16, 17]


Blok dijagram serijskog proizvodnog sustava prikazan je slikom 3.3. Krugovi predstavljaju proizvodne jedinice m_i (pojedinačni strojevi, radne stanice, toplinska obrada i dr.), a pravokutnici uređaje za rukovanje materijalom b_i (transporteri, automatski vođena vozila, i dr.). [17]



Slika 3.3. Blokdijagram serijskog proizvodnog sustava [17]


Uz proizvodne jedinice m_i , serijski proizvodni sustav može uključivati i kontrolne poslove kojima je cilj pronaći i ukloniti neispravne dijelove proizvedene u sustavu. Takav proizvodni sustav prikazan je na slici 3.4 gdje su tamno plavim krugovima prikazani strojevi koji mogu proizvesti neispravne dijelove m_{Ni} , dok su sivom bojom ispunjeni krugovi koji predstavljaju

inspekcijske uređaje r_i . Strelica na inspekcijskom stroju upućuje na odbacivanje neispravnih dijelova. [17]



Slika 3.4. Serijski proizvodni sustav s kontrolom kvalitete proizvoda [17]


Još jedan oblik serijskog proizvodnog sustava jest onaj s dodatnom obradom. Ako je neispravan proizvod proizveden, on se popravljiva vraćanjem na odgovarajuću operaciju i na daljnju obradu. Primjer serijskog proizvodnog sustava s dodatnom obradom prikazan je na slici 3.5. [17]



Slika 3.5. Serijski proizvodni sustav s dodatnom obradom [17]


Serijski proizvodni sustav najčešće je korišten sustav proizvodnje. Teško je pronaći proizvodni sustav koji ne uključuje jednu ili više serijskih proizvodnih linija. [17]

Montažni proizvodni sustav – onaj je sustav kada se dvije ili više serijskih proizvodnih linija spajaju u jednoj ili više operacija u kojima se komponente sastavljaju, te se kroz nekoliko uzastopnih operacija oblikuju u montažni dio [17]. Blok dijagram tipičnih proizvodnih montažnih sustava prikazan je slikom 3.6. Kao i kod serijskih proizvodnih sustava, krugovi predstavljaju proizvodne jedinice m_i , a pravokutnici uređaje za rukovanje materijalom b_i .



Slika 3.6. Montažni proizvodni sustav: a.) s jednim spajanjem operacija, b.) s višestrukim spajanjem operacija [17]

Kompleksni proizvodni sustav često se susreće u praksi. Obično se sastoji iz raznih kombinacija prethodno opisanih proizvodnih sustava, pri čemu u pojedinim segmentima dolazi do njihova preklapanja [17]. Blok dijagram kompleksnog proizvodnog sustava prikazan je na slici 3.7.



Slika 3.7. Kompleksni proizvodni sustav [17]


Ovisno o proizvodu koji se proizvodi odabire se odgovarajući proizvodni sustav. Sam način planiranja i praćenja proizvodnje razlikuje se po tehnikama i metodama ovisno o vrsti proizvodnog sustava [3].

3.3. Upravljanje proizvodnim sustavima

Pojmovi upravljanje i menadžment za većinu autora imaju isto značenje, odnosno predstavljaju sinonime. Međutim, navedene pojmove, osim male sadržajne sličnosti, odlikuju različitosti. [18]

- *Upravljanje* se temelji na pravu vlasništva nad materijalnim i ostalim čimbenicima proizvodnje, odnosno poslovanja. Onaj tko je vlasnik čimbenika proizvodnje, taj je ujedno i nositelj funkcije upravljanja. Nositelji funkcije upravljanja određuju i nositelje menadžerskih aktivnosti.
- *Menadžment* predstavlja izvršnu aktivnost upravljanja. Menadžment je proces u kojem se koordiniraju aktivnosti drugih ljudi, a pomoću tih se aktivnosti ostvaruju ciljevi organizacije uz efikasnu i efektivnu uporabu svih raspoloživih resursa organizacije.

Osnovne razine menadžmenta, nosioci menadžerskih uloga na pojedinim razinama menadžmenta kao i poslovi odnosno zadaci pojedinih razina menadžmenta prikazani su organizacijskom piramidom na slici 3.8.



Slika 3.8. Organizacijska piramida [18]

Organizaciju upravljanja određuju dioničari, vlasnici ili članovi trgovačkog društva u skladu sa *Zakonom o trgovačkim društvima*. Upravljanje predstavlja proces mijenjanja postojećeg stanja u društvu u skladu s postavljenim ciljem ili planom, a realizira se kroz proces donošenja upravljačkih odluka i njihovu provedbu. Upravljanje se dijeli na strateško, taktičko i operativno. Navedene razine upravljanja obavlja vrhovni menadžment, menadžment srednje razine i menadžment prve razine. [1, 3, 16, 18]

Strateško upravljanje održava skup dugoročnih ciljeva koji će biti realizirani taktičkim i operativnim upravljanjem kroz poslovne politike poduzeća. Strateškim se upravljanjem određuju standardi rukovođenja kroz kontrolni sustav kritičnih točaka. [18]

Uprava društva, menadžment, vodi poslovanje društva i raspolaže rukovodećom kontrolom. Kontrola rukovođenja podrazumijeva postavljanje ciljeva i podciljeva društva i njihovo ostvarenje. Rukovodeće odluke donose se na temelju određene metodologije procesa odlučivanja uz poštivanje postojećih postavljenih procedura, pravila, uputa i propisa. Uprava društva donosi rukovodeće odluke o proizvodnji, prodaji, proizvodnom programu – asortimanu, tehnologiji te zapošljavanju radnika i vanjskih suradnika. [16, 18]

Sam način upravljanja proizvodnim sustavima ovisi o vrsti tehnološkog procesa sustava, odnosno o proizvodu koji se proizvodi. Uobičajena je podjela na četiri vrste proizvodnje: pojedinačnu, serijsku, masovnu i procesnu.

3.3.1. Vrste proizvodnje

Uobičajena podjela proizvodnje, koja se često navodi u literaturi [1, 3, 19], a ovisno o proizvodu koji se proizvodi jest: pojedinačna proizvodnja, serijska proizvodnja (maloserijska i velikoserijska), masovna proizvodnja (roba široke potrošnje) i procesna proizvodnja (proizvodi se u šaržama).

Pojedinačna proizvodnja jest proizvodnja jednog ili nekoliko komada proizvoda prema zahtjevima kupca. Posebnost je te vrste proizvodnje mali kapacitet proizvodnje i velika mogućnost proizvodnje različitih vrsta proizvoda. U postupku proizvodnje upotrebljavaju se standardni strojevi na kojima rade vrlo vješti radnici, jer svaki proizvod predstavlja izazov

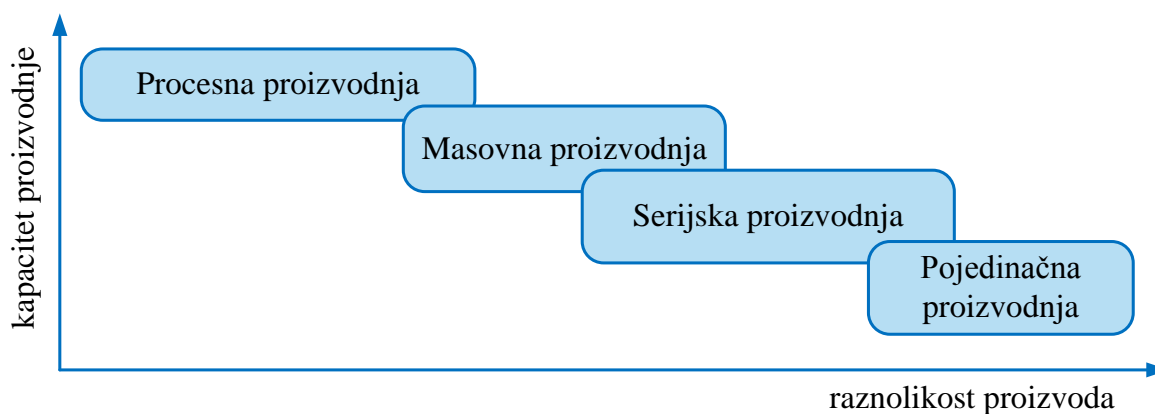
zbog jedinstvenosti. Naravno, za definiranje tijeka izrade proizvoda, kapaciteta strojeva i prioriteta izrade nužno je detaljno planiranje. [1, 3]

Serijska proizvodnja jest proizvodnja određenog broja proizvoda u određenim serijama. Serijsku proizvodnju karakterizira kraće trajanje proizvodnje te veća fleksibilnost postrojenja i strojeva. Postrojenje i strojevi prilagođeni su za proizvodnju proizvoda u serijama, dok je za proizvodnju druge serije potrebno ponovno prilagoditi strojeve. Vodeće vrijeme proizvodnje i cijena proizvodnje manji su u odnosu na pojedinačnu proizvodnju. [1, 3]

Masovna proizvodnja predstavlja proizvodnju zasebnih dijelova ili sklopova u kontinuiranom procesu. Ovaj proizvodni sustav primjenjuje se za proizvodnju vrlo velikog broja proizvoda – veliki kapacitet proizvodnje. Postupak proizvodnje odvija se u jednom smjeru u kojem je izlaz iz jednog proizvodnog postupka ulaz u drugi. Odlike masovne proizvodnje jesu: standardizacija proizvoda i slijed proizvodnje, veliki proizvodni kapaciteti, kraće vrijeme proizvodnje, manje zalihe, kontinuiran tijek materijala, komponenti i dijelova i sl. [1, 3]

Procesna proizvodnja odvija se u slijedu po proizvodnim operacijama od prvih operacija sve do gotovog proizvoda. Karakteristike su procesne proizvodnje: namjenska postrojenja i oprema bez fleksibilnosti, rukovanje materijalom u potpunosti je automatizirano, tijek procesa unaprijed je definiran slijed operacija, sastavni materijali (komponente) ne mogu se lako odrediti u konačnom proizvodu i sl. [1, 3]

Primjena pojedinih vrsta proizvodnje ovisno o kapacitetu proizvodnje i mogućnosti proizvodnje raznolikih proizvoda prikazana je slikom 3.9.



Slika 3.9. Vrste proizvodnje [1]

Prednosti i nedostaci/ograničenja navedenih vrsta proizvodnje navedeni su u tablici 3.2.

Tablica 3.2. Prednosti i nedostaci/ograničenja prema vrstama proizvodnje [1]

	prednosti	nedostaci/ograničenja
Pojedinačna proizvodnja	<ul style="list-style-type: none"> - upotreba standardnih strojeva - radnici na strojevima stječu sve više vještina i sposobnosti (kompetencija) - gotovo svaki posao (proizvod) uči ih nečem novom - može se iskoristiti puni potencijal radnika - postoji mogućnost razvijanja kreativnih metoda i inovativnih ideja 	<ul style="list-style-type: none"> - viši troškovi proizvodnje zbog većih promjena proizvodnje - viša razina zaliha na svim razinama, time i veći troškovi zaliha - komplicirano planiranje proizvodnje - veći zahtjevi za prostorom
Serijska proizvodnja	<ul style="list-style-type: none"> - bolja iskoristivost postrojenja i strojeva - potiče se funkcionalna specijalizacija - manji trošak po jedinici proizvoda u odnosu na pojedinačnu proizvodnju - manja ulaganja u postrojenja i strojeve 	<ul style="list-style-type: none"> - rukovanje materijalom složenije je zbog nepravilnih i dužih tokova proizvodnje - složenije planiranje i kontrola proizvodnje - zalihe nedovršenih proizvoda veće su u odnosu na kontinuiranu proizvodnju - visoki troškovi podešavanja (prilagodbe) strojeva zbog čestih promjena šarži
Masovna proizvodnja	<ul style="list-style-type: none"> - viša stopa proizvodnje sa smanjenim vremenom ciklusa proizvodnje - veća iskorištenost kapaciteta - mogu raditi manje iskusni radnici - niska cijena po jedinici proizvoda 	<ul style="list-style-type: none"> - zaustavljanje jednog stroja zaustavlja cijelu liniju - promjena dizajna proizvoda zahtijeva velike promjene na proizvodnoj liniji - visoka ulaganja u proizvodne pogone - vrijeme ciklusa određuju najsporije operacije
Procesna proizvodnja	<ul style="list-style-type: none"> - standardizacija proizvodnje i smanjeno vrijeme ciklusa proizvodnje - veća iskorištenost kapaciteta s obzirom na balansiranje linije - potpuna automatizacija procesa proizvodnje - jedinični trošak je to manji što je veći kapacitet proizvodnje 	<ul style="list-style-type: none"> - ne postoji fleksibilnost proizvodnje - vrlo visoke investicije za postavljanje toka proizvodnje - ograničena proizvodnja različitih proizvoda

3.3.2. Proizvodni menadžment

Upravljanje proizvodnim sustavom je specijalizirana aktivnost koju obavljaju vrhovni menadžeri i menadžeri poslovnog područja proizvodnje. Proizvodni menadžment uključuje proces planiranja, organiziranja, vođenja i kontroliranja aktivnosti proizvodnih funkcija. On također kombinira i pretvara različite resurse koji se primjenjuju u proizvodnim podsustavima organizacije, pri čemu se proizvodu dodaje vrijednost na kontrolirani način i po pravilima organizacije. [1, 13, 19]

Specifičnost proizvodnog menadžmenta proizlazi iz karakteristika procesa proizvodnje, kao dijela ciklusa poslovanja poduzeća. Proces proizvodnje određen je zahtjevima kupaca, kao i mogućnostima poduzeća da zadovolji te zahtjeve. Upravljanje proizvodnjom usko je povezano sa sektorom marketinga, financija, kadrova, istraživanja, razvoja i dr. [1, 13, 19]

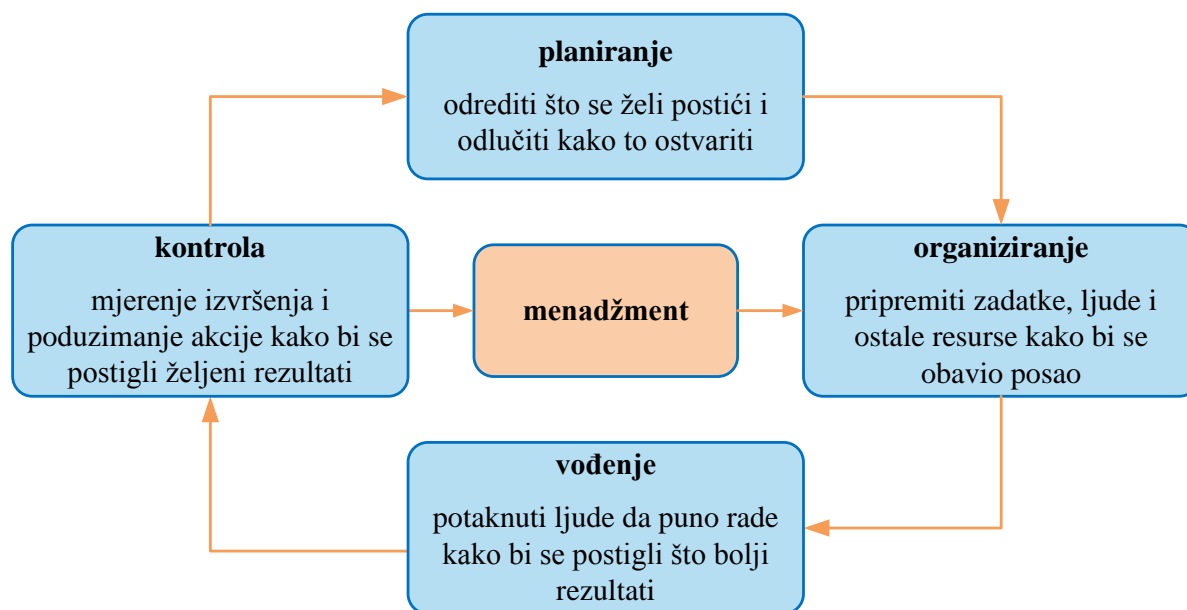
3.3.2.1. Ciljevi proizvodnoga menadžmenta

Menadžment poduzeća, bez obzira na to radi li se o proizvodnji robe ili usluga, mora osigurati postizanje i poštivanje konačnog cilja, a to je: [1, 19]

- proizvesti u pravo vrijeme. Pravodobnost isporuke jedan je od važnih parametara učinkovitosti odjela proizvodnje, stoga odjel proizvodnje mora optimalno primijeniti ulazne resurse kako bi postigao svoj cilj.
- proizvesti kvalitetan proizvod. Kvaliteta proizvoda temelji se na potrebama kupaca. Ispravna kvaliteta ne mora nužno biti i najbolja kvaliteta. Kvaliteta je određena cijenom proizvoda i tehničkim karakteristikama koje su prilagođene specifičnim zahtjevima.
- proizvesti u traženoj količini. Proizvodna organizacija treba proizvesti proizvode u ispravnoj količini. Ako se proizvodi u količinama većim od potražnje roba/usluga, kapital će biti blokiran u obliku zaliha proizvoda, dok proizvodnja u količinama manjim od potražnje dovodi do manjka proizvoda.
- proizvesti uz najmanje troškove. Proizvodni troškovi određeni su prije nego je proizvod proizveden. Dakle, proizvode je potrebno proizvesti po planiranim troškovima, kako bi se smanjila odstupanja između stvarnih i planiranih troškova.

3.3.2.2. Aktivnosti proizvodnoga menadžmenta

Glavne su aktivnosti proizvodnog menadžmenta: planiranje, organiziranje, vođenje i kontrola. (slika 3.10). [1, 2, 19]



Slika 3.10. Funkcije menadžmenta [18]

Planiranje proizvodnje kao primarna funkcija proizvodnog menadžmenta obuhvaća odlučivanje o strateškim ciljevima proizvodnje, te operativnim ciljevima i zadacima u svim njenim dijelovima. [1, 2, 19]

- Strateški ciljevi proizvodnje usmjereni su na:
 - *Proizvod – strategija proizvoda* usmjerena je na izbor asortimana kojim će se na najbolji način zadovoljiti potrebe kupaca. Proizvodi se razlikuju po tome da li se izrađuju po narudžbi kupca ili imaju standardnu namjenu. U zavisnosti od namjene proizvoda odabire se odgovarajuća strategija, koja je usmjerena na postizanje što većeg profita po jedinici uloženog kapitala.
 - *Proizvodni proces - strategija proizvodnog procesa* obuhvaća odlučivanje o izboru odgovarajuće tehnologije koja osigurava racionalno korištenje kapitala.
 - *Korištenje kapaciteta - strategija korištenja kapaciteta* obuhvaća upravljačke aktivnosti i usmjerena je na organizacijsku strukturu proizvodnje prema asortimanu proizvoda.
- Operativni ciljevi proizvodnje predstavljaju razradu strateških planova na neposredne zadatke prema pojedinim segmentima proizvodnje.

Organiziranje proizvodnje obuhvaća upravljačke aktivnosti razrade globalnih organizacijskih rješenja u vezi s ulogom i položajem proizvodnje u procesu poslovanja poduzeća. Određuju se aktivnosti potrebne za postizanje ciljeva i dodjeljuju ovlasti i odgovornosti za njihovo izvršenje. Npr. ako se poduzeće odluči za proizvodnju po narudžbi kupaca, odgovarajući oblik organizacije bit će pojedinačna proizvodnja u slučaju odluke za standardne proizvode, odgovarajući oblik organizacije bit će serijska proizvodnja. [2, 19]

Vođenje proizvodnje usmjereno je na racionalnu primjenu ljudskih resursa. Strateški dio vođenja obuhvaća kadrovsku politiku, međuljudske odnose i načela motivacije, što je pretežno u nadležnosti vrhovnog menadžmenta. Neposredno komuniciranje s izvršiteljima u nadležnosti je proizvodnog menadžmenta, jer oni imaju uvid u radne mogućnosti i ostvarene rezultate svakog radnika, a to im omogućuje da odaberu odgovarajuće metode motivacije. [2, 19]

Kontroliranje proizvodnje je funkcija proizvodnog menadžmenta kojom se zaokružuje upravljačka aktivnost u ovom području poslovanja. Za kontroliranje proizvodnje karakteristično je raslojavanje na strateški i operativni dio. U okviru strateških odluka utvrđuju se osnovni ciljevi i načela kontrole proizvodnje. Zatim se provodi operativna kontrola, koja obuhvaća nadzor nad izvršavanjem pojedinačnih ciljeva, kao i poduzimanje mjera da se osigura izvršavanje zadataka. Sustav kontrole zahtijeva odgovarajuće informacije o ulaganjima i rezultatima poslovnih jedinica, kako bi se pravodobno uočili uzroci negativnih odstupanja od plana i poduzele odgovarajuće mjere za ostvarenje planiranih ciljeva. [2, 19]

Iz navedenog se vidi da je upravljanje proizvodnim sustavima složen proces. Svakako je potrebno mjeriti relevantne pokazatelje proizvodnih sustava kako bi se vidjelo da li proizvodni sustav ispunjava definirane ciljeve, odnosno je li u skladu sa strategijom i vizijom poduzeća. U tu svrhu primjenjuje se metrika proizvodnih sustava kojom se mjere različiti pokazatelji učinkovitosti i konkurentnosti proizvodnih sustava, koji su opisani u nastavku.

3.4. Metrika proizvodnih sustava

Kod metrike proizvodnih sustava pojavljuju se dva glavna pitanja, a to su što i kako izmjeriti? Glavni cilj svakog poduzeća za postizanje poslovnog uspjeha u konkurentnom okruženju je profit i vodeća pozicija. Na općoj razini, metrika se može izraziti u smislu profita, povrata investicije i ostalih financijskih pokazatelja. Unutar poduzeća postoji niz čimbenika koji doprinose uspješnosti. Jedna od njih može biti proizvodni sustav, koji izravno ili neizravno doprinosi poslovnom uspjehu poduzeća. [2, 17]

Potrebno je mjeriti učinkovitost proizvodnih sustava jer nam ona kazuje da li se smanjuje ili povećava uspješnost poduzeća. U nastavku se navode neki od pokazatelja učinkovitosti proizvodnih sustava.

3.4.1. Pokazatelji učinkovitosti proizvodnih sustava

Produktivnost i efikasnost

Produktivnost (e. *productivity*) i efikasnost (djelotvornost, e. *efficiency*) mjere su koje se najčešće primjenjuju za opisivanje učinkovitosti proizvodnih sustava. Produktivnost je apsolutna mjera, koja navodi odnos između onoga što je postignuto u proizvodnji i uloženog napora u ostvarenju toga, te je definirana izrazom 3.2: [2]

$$produktivnost = \frac{izlaz}{ulaz} \quad (3.2)$$

Mjerenje produktivnosti kao takvo uglavnom se primjenjuje za usporedbe, npr. da se vidi da li se primjena raspoloživih resursa promijenila tijekom vremena. Na osnovi izraza 3.2 zaključuje se da veća produktivnost dovodi do smanjenja troškova proizvodnje, ujedno smanjuje cijenu proizvoda, čime proširuje tržišta, jer je proizvod konkurentniji. [2]

Problem prikaza produktivnosti navedenog izrazom 3.2 u tome je što je potrebno definirati ulaz i izlaz. Uobičajen je izraz prikaza produktivnosti koji se temelji na vremenu, odnosno prikazan je odnosom između vremena dodavanja vrijednosti proizvodu (izlaz) i ukupnog

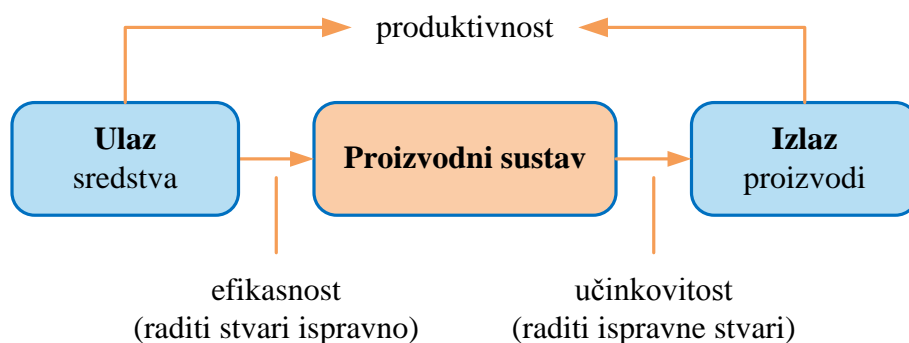
vremena proizvodnje (ulaz). Produktivnost temeljena na vremenu prikazana je izrazom 3.3: [2]

$$P = \frac{t_{va}}{t_{tot}} \times 100 \quad (3.3)$$

gdje je: P [%] – produktivnost, t_{va} [s, min, h] – vrijeme dodavanja vrijednosti, t_{tot} [s, min, h] – ukupno vrijeme.

Kako bi se izbjeglo krivo tumačenje primjene produktivnosti kao mjere uspješnosti proizvodnog sustava, važno je uvijek jasno navesti kako je definirana produktivnost i na što se točno odnosi. [2]

Teško je objasniti razliku između efikasnosti, odnosno djelotvornosti (e. *efficiency*) i učinkovitosti, odnosno efektivnosti (e. *effectiveness*). Kada se govori o proizvodnom sustavu, veza između produktivnosti, efikasnosti i učinkovitosti prikazana je slikom 3.11.



Slika 3.11. Povezanost produktivnosti, efikasnosti i učinkovitosti proizvodnog sustava [2]

Kao što je prikazano na slici 3.11, efikasnost se odnosi na ulazne veličine, dok je učinkovitost vezana na izlazne veličine proizvodnog sustava. Sustav je efikasniji kada se određeni izlaz (proizvod) dobiva iz minimalnog broja ulaznih veličina, npr: troškova, napora ili gubitaka. Efikasnost predstavlja postizanje definiranih zahtjeva s minimalnom količinom resursa, dok je učinkovitost ocjena odnosa između postignutog rezultata i postavljenog cilja.

Ukupna učinkovitost opreme

Ukupna učinkovitost opreme (e. *overall equipment effectiveness* - *OEE*) također se temelji na vremenskoj bazi i sastoji se od tri pokazatelja: [2, 20, 21]

- stopa dostupnosti – predstavlja zastoje zbog kvara na opremi i potrebnog vremena rješavanja kvara u postotnom iznosu od predviđenog vremena
- stopa učinkovitosti – predstavlja rad brzinom manjom od projektirane
- stopa kvalitete – predstavlja gubitak defektnih proizvoda i dorade kao postotak u odnosu na ukupno proizvedene proizvode

Množenjem ovih pokazatelja dobiva se ukupna učinkovitost opreme (izraz 3.4): [2, 20]

$$\begin{aligned} \text{ukupna učinkovitost opreme} &= \text{stopa dostupnosti} \times \text{stopa} \\ &\text{učinkovitosti} \times \text{stopa kvalitete} \end{aligned} \quad (3.4)$$

Navedeni pokazatelji: stopa dostupnosti, stopa učinkovitosti i stopa kvalitete definirani su izrazima 3.5, 3.6 i 3.7: [2, 20]

$$\begin{aligned} \text{stopa} &= \frac{\text{raspoloživo vrijeme} - \text{zastoj}}{\text{raspoloživo vrijeme}} \times 100 \\ \text{dostupnosti} \end{aligned} \quad (3.5)$$

$$\begin{aligned} \text{stopa} &= \frac{\text{idealno vrijeme ciklusa} \times \text{proizvedeni proizvodi}}{\text{vrijeme rada}} \times 100 \\ \text{učinkovitosti} \end{aligned} \quad (3.6)$$

$$\begin{aligned} \text{stopa} &= \frac{\text{proizvedni proizvodi} - \text{defektni proizvodi}}{\text{proizvedeni proizvodi}} \times 100 \\ \text{kvalitete} \end{aligned} \quad (3.7)$$

Veća ukupna učinkovitost opreme (OEE) postiže se smanjenjem gubitaka, koji obuhvaćaju: kvarove, podešavanja, zastoje, smanjenje radne brzine, defektne proizvode, dorade i sl. OEE je korisna mjera za određivanje učinkovitosti poluautomatskih i automatskih proizvodnih sustava. Ciljevi kojima treba težiti, prema pojedinim pokazateljima jesu: stopa dostupnosti više od 90 %, stopa učinkovitosti više od 95 % te stopa kvalitete više od 99 % [21].

Učinkovitost ručne montaže

Učinkovitost ručne montaže (e. *manual assembly efficiency* - MAE) razmatra mogućnost promjena potrebnog vremena, koje se može pojaviti prilikom ručne montaže. Učinkovitost ručne montaže definirana je izrazom 3.8: [2]

$$MAE = \frac{\sum_{i=1}^N (t_{lai} - t_{Ri})}{N_A (t_{TOT} - t_{PS} - t_{UN})} \times 100 \quad (3.8)$$

gdje je: MAE [%] – učinkovitost ručne montaže, N – broj sastavljenih jedinica, t_{lai} [s, min, h] – idealno vrijeme za montažu jedne jedinice, t_{Ri} [s, min, h] – vrijeme dodatne obrade nakon procesa montaže jedinice, N_A – broj montera, t_{TOT} [s, min, h] – ukupno raspoloživo vrijeme, t_{PS} [s, min, h] – ukupno planirano vrijeme zaustavljanja, t_{UN} [s, min, h] – ukupno neiskorišteno vrijeme montaže.

3.4.2. Pokazatelji konkurentnosti proizvodnih sustava

Odgovarajuće pokazatelje konkurentnosti proizvodnih sustava koji su mjerljivi teško je pronaći. Općenito je prihvaćeno da samo financijski pokazatelji nisu dovoljni. Za dobivanje kvalitetnih informacija o proizvodnom sustavu, na osnovi kojih će se donositi kvalitetne odluke, potrebno je napraviti cjelovitu analizu proizvodnih sustava. Pod cjelovitom analizom misli se na analizu sljedećih pokazatelja konkurentnosti: [2]

- troškovi (materijala, rada i sl.)
- kvaliteta proizvoda
- brzina isporuke
- pouzdanost isporuke
- fleksibilnost reagiranja na promjene.

Jedan od načina utvrđivanja mjerljivih pokazatelja proizvodnih sustava jest analiza proizvodne strategije. Pri određivanju pokazatelja proizvodnih sustava važno je da oni podržavaju definirane ciljeve, čime se podržava ukupna strategija i vizija poduzeća. [2]

Tablični prikaz mjera učinkovitosti proizvodnog sustava ovisno o pokazateljima konkurentnosti, odnosno ciljevima poslovanja poduzeća, dan je tablicom 3.3.

Tablica 3.3. Ciljevi poslovanja, objašnjenje i pokazatelji [2]

Cilj poslovanja	Objašnjenje	Pokazatelj
Smanjenje troškova	Troškovi materijala, rada i drugih sredstava za proizvodnju proizvoda	Jedinični trošak proizvodnje Troškovi u odnosu na konkurente Produktivnost Trošak rada Zalihe
Kvaliteta	Proizvodnja proizvoda što veće kvalitete	Broj pritužbi Jamstvo Postotak loših proizvoda Trošak dorade loših proizvoda Kvaliteta ulaznih komponenti Vrijeme između kvarova
Brzina	Brzina isporuke	Vrijeme ciklusa proizvodnje Vrijeme isporuke dobavljača
Pouzdanost	Pouzdanost isporuke	Postotak isporuke na vrijeme Prosječno kašnjenje Udio proizvoda u skladištu
Fleksibilnost	Sposobnost reagiranja na promjene: količine, proizvodnog asortimana, dizajna proizvoda i sl.	Vrijeme podešavanja Vrijeme potrebno za razvoj proizvoda Asortiman proizvoda Vrijeme potrebno za promjenu plana Minimalna količina narudžbe Postotak stručne radne snage

3.4.3. Kontinuirano praćenje učinkovitosti proizvodnih sustava

Na proizvodnom sustavu potrebno je kontinuirano provoditi mjerenje i vrednovanje proizvodnih pokazatelja, radi učinkovitoga upravljanja sustavom. Kontinuirano mjerenje odabranih pokazatelja obično se provodi opremom za automatsko očitavanje. Izmjereni podaci zatim se obrađuju nekim od programskih paketa koji omogućavaju lakše praćenje i analizu izmjerenih podataka. Kontinuirano vrednovanje proizvodnog sustava i operacija često se naziva praćenje, a ono se odnosi na mjerenje i metode kontinuirane kontrole i upravljanja proizvodnim sustavima. [2]

Ako mjerenja performansi proizvodnog sustava ne obuhvaćaju relevantne pokazatelje, postoji potencijalna opasnost da se dostupno vrijeme ne upotrebljava na odgovarajući način, a to dovodi do: gomilanja proizvoda u skladištima, povećanja troškova i dr. Ako rezultati mjerenja uspješnosti daju ispravnu sliku trenutnih aktivnosti, poželjno je i dalje nastaviti s mjerenjem i praćenjem tih pokazatelja. [2, 22]

Nakon što su određeni pokazatelji proizvodnog sustava koji će se mjeriti, često nije jednostavno izvesti njihovo mjerenje. Prema *Međunarodnom Protokolu za mjerenje i verifikaciju učinka*, opcije mjerenja moguće je podijeliti u četiri grupe: [22]

- A) pojedinačna mjerenja – ključni parametri (podsustav)
- B) grupa mjerenja – mjerenje svih parametara (sustav kao cjelina)
- C) mjerenje sustava zajedno s okolinom (sustav i okolina)
- D) simulacija – korištenjem programa za simulacije.

Sama mjerenja ne daju smjernice niti pružaju cjelovitu sliku o aktivnostima. Međutim rezultati dobiveni mjerenjem imaju znatnu ulogu u kontroli raznih aktivnosti, kao što su: [2]

- davanje uvida u odstupanja od ciljeva koji mogu podržati odluku o mogućim aktivnostima za ispravljanje situacije
- poticanje poboljšanja procesa kontrole
- usklađivanje i komunikacija ciljeva, ugovora i politika poduzeća
- podrška odlukama o nagrađivanju
- opravdanost postojanja sustava mjerenja
- motivacija zaposlenika kroz povratne informacije.

Na osnovi navedenog važno je napomenuti da su kombinacijom mjerenja različitih mjera uspješnosti stvarne aktivnosti proizvodnih sustava bolje opisane, a rezultati mjerenja moraju biti povezani s ciljevima, ranijim mjerenjima i sl. Važno je mjeriti prave stvari pa mjerenja učinkovitosti proizvodnog sustava moraju biti podržane od menadžmenta poduzeća.

Kod mjerenja je važno da izmjerene veličine prikazuju stvarno stanje sustava, kako bi se mogle donijeti kvalitetne odluke. Međutim, kod mjerenja je važno obratiti pozornost na to da se ne mjeri previše veličina, jer je previše informacija jednako loše kao i premalo informacija. [2, 22]

Može se reći da se uvjeti u industrijskoj proizvodnji stalno mijenjaju. Kupci očekuju niže cijene proizvoda vrlo visoke kvalitete koji će biti isporučeni u pravo vrijeme. U današnje vrijeme nije dovoljno razviti jedan uspješan proizvod, jer je potražnja za novim proizvodima beskrajna, stoga je potrebno kontinuirano razvijati nove proizvode. Potrebno je podupirati razvoj proizvodnje kroz razvoj alata i tehnika učinkovitoga upravljanja proizvodnim sustavima. [2, 23]

4. SUVREMENE TEHNIKE I ALATI UČINKOVITOGA UPRAVLJANJA PROIZVODNIM SUSTAVIMA / PODUZEĆIMA

U suvremenom okruženju, čije je glavno obilježje stalna promjena konkurentnosti, poduzeća moraju posvetiti znatno vrijeme i resurse kako bi ostvarila svoje strateške ciljeve. Promjene poslovnih procesa potrebne su ne samo zbog novih tehnologija, nego i zbog želje za povećanjem učinkovitosti i produktivnosti poduzeća. Dolazi do promjena uvjeta u proizvodnji te se javljaju novi zahtjevi na upravljačke sustave poduzeća. Sasvim je očito da postoji potreba za upravljačkim sustavima koji bi uravnotežili povijesne financijske podatke i suvremene promicatelje poslovnog uspjeha na takav način koji omogućuje učinkovito obavljanje poslovne strategije. [5]

Kako bi poduzeće ostalo konkurentno na tržištu, sve više se javlja potreba za detaljnim praćenjem i izvještavanjem o različitim dijelovima poslovanja. Kao odgovor na te potrebe razvijeno je tijekom osamdesetih i devedesetih godina prošlog stoljeća nekoliko tehnika i alata učinkovitoga upravljanja, od kojih se neki navode u tablici 4.1.

Tablica 4.1. Suvremene tehnike i alati učinkovitoga upravljanja [5]

Kratica	Tehnike i alati učinkovitoga upravljanja
6σ	Šest sigma (e. <i>Six Sigma</i>)
BPR	Re-inžernjering poslovnih procesa (e. <i>Business Process Reengineering</i>)
BSC	Uravnotežene kartice rezultata (e. <i>Balanced Scorecard</i>)
JIT	Proizvodnja u pravo vrijeme (e. <i>Just-In-Time Production</i>)
SMED	Brza izmjena alata (e. <i>Single Minute Exchange of Dies</i>)
TPM	Cjelovito produktivno održavanje (e. <i>Total Productive Maintenance</i>)
TQM	Potpuno upravljanje kvalitetom (e. <i>Total Quality Management</i>)
	20 ključeva (e. <i>20 keys</i>)
	Vitka proizvodnja (e. <i>Lean Production</i>)

Navedene suvremene tehnike i alati učinkovitoga upravljanja dolazile su u sukob s tradicionalnim alatima za upravljanje budući da su poticale konstantan napredak poslovanja poduzeća kroz zamisli i prijedloge koji dolaze iz same organizacije. Novim, strateškim

upravljanjem poduzećem javlja se potreba za novim informacijama kako bi se provelo uspješno planiranje, donošenje odluka, nadziranje i kontrola. Iz tog razloga upravljački sustav mora uzeti u obzir i vanjske čimbenike kako bi uključio strateške informacije koje pokazuju hoće li tvrtka i njeno poslovanje biti konkurentno u nastupajućem vremenu. [2, 5]

U nastavku se daju kratki opis te značajke i karakteristike nekoliko suvremenih tehnika i alata učinkovitoga upravljanja poduzećima, navednih u tablici 4.1, a čija je namjena poboljšanje kvalitete, cijene, vremena izrade i sl. Opisane su tehnike i alati stalnog poboljšanja: šest sigma, re-inženjering poslovnih procesa, uravnotežene kartice rezultata, cjelovito produktivno održavanje, cjelovito upravljanje kvalitetom, metodologija 20 ključeva te vitka i zelena proizvodnja.

U tablici 4.1 navedene su tehnike i alati učinkovitoga upravljanja SMED i JIT koje u nastavku rada nisu zasebno obrađene jer su dio vitke proizvodnje koja je opisana u potpoglavlju 4.7. Također, u potpoglavlju 4.8 obrađena je zelena proizvodnja koja je sastavni dio suvremenih tehnika i alata učinkovitoga upravljanja proizvodnjom / poduzećima, a odnosi se na smanjenje rasipanja resursa i štetnog utjecaja na okoliš. Zelena proizvodnja nije navedena u tablici 4.1 koja je preuzeta od onih autora [5] koji zelenu proizvodnju nisu obuhvatili svojim istraživanjem.

4.1. Šest sigma (e. *Six Sigma* - 6σ)

Šest sigma (e. *Six Sigma*) predstavlja poslovnu filozofiju koja se fokusira na stalno unaprjeđenje razumijevanja korisničkih potreba, analizu poslovnih procesa i prihvatanje vlastitih mjernih značajki te tako postiže izvrsnost proizvoda i pružanja usluga korisnicima [23]. Metodu šest sigma razvio je inženjer *Motorole* Bill Smith 80-ih godina prošlog stoljeća, a ona mu je služila kao alat za statističku kontrolu procesa kako bi smanjio odstupanja u proizvodnji. Počela se primjenjivati u svim djelatnostima, a veliku popularnost doživjela je 1995. godine kada je proglašena najvažnijom inicijativom kompanije *General Electric*. [24]

Kako bismo poboljšali organizacijsku razinu procesa, potrebno je smanjiti broj varijacija u procesu jer se time postiže bolja predvidljivost procesa i smanjuju se vremenski gubici.

Također je potrebno izbjegavati suvišne operacije jer time proizvodi i usluge postaju kvalitetniji a korisnici zadovoljniji. Koncept šest sigma temelji se na primjeni statističkih alata i mjerenja odstupanja (standardne devijacije - σ) od srednje vrijednosti statističke distribucije (Gaussova razdioba) neke pojave (npr: radne operacije, aktivnosti ili procesa). Kada proces djeluje na razini šest sigma, varijacija je tako mala da rezultira točnošću od 99,99966 %, odnosno 3,4 proizvoda s greškom (nesukladna proizvoda) na milijun proizvedenih jedinica. Tablica 4.2 prikazuje broj proizvoda s greškom (nesukladnih proizvoda) u ovisnosti o sigma razini. [23, 24]

Tablica 4.2. Definiranje sigma razine [25]

Sigma (σ) razina	postotak sukladnih	Broj nesukladnih na milijun proizvedenih
1 σ	30,23 %	697 700
2 σ	69,13 %	308 700
3 σ	93,32 %	66 810
4 σ	99,379 %	6 210
5 σ	99,9767 %	232,7
6 σ	99,99966 %	3,4

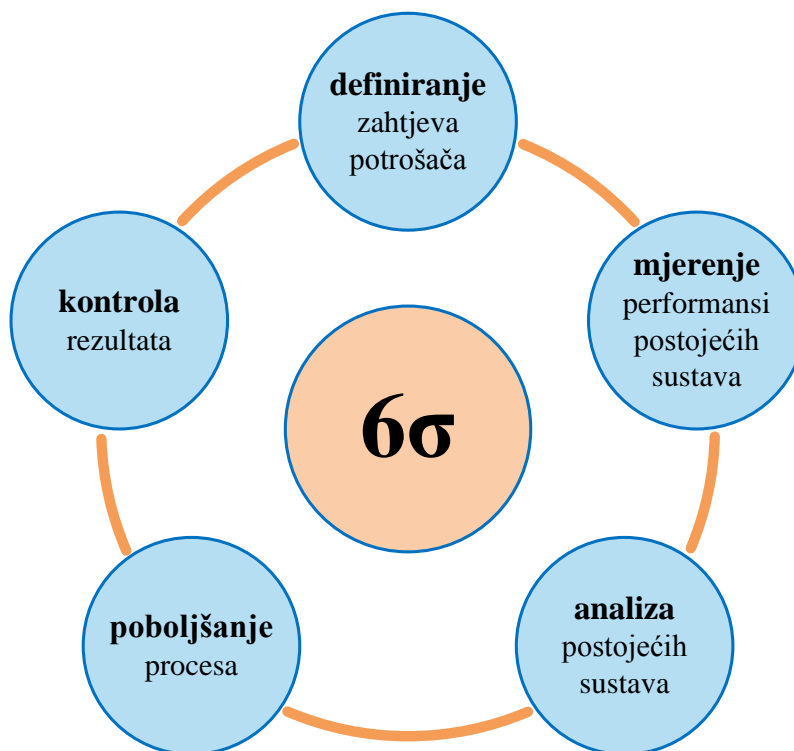
U praksi se primjenjuju dvije osnovne šest sigma metode:

- DMAIC – definiraj, mjeri, analiziraj, poboljšaj, kontroliraj (e. *Define, Measure, Analyze, Improve, Control*) i
- DMADV – definiraj, mjeri, analiziraj, oblikuj, provjeri (e. *Define, Measure, Analyze, Design, Verify*).

DMAIC metoda primjenjuje se za poboljšanje postojećeg poslovnog procesa, dok se DMADV metoda primjenjuje kada je potrebno razviti novi proces, kreirati proizvod ili stvoriti novu uslugu, kao i u situacijama kada je potrebno napraviti kompletno restrukturiranje tvrtke ili nekog njenog procesa [23]. Prema DMAIC metodi šest sigma projekt provodi se u pet faza, prikazanih slikom 4.1. Navedene faze jesu: [26]

- definiranje problema i zahtjeva potrošača
- mjerenje nedostataka i procesnih operacija (performansi postojećeg sustava)
- analiziranje podataka i otkrivanje uzroka problema

- poboljšanje procesa radi uklanjanja uzroka nedostataka
- kontrola procesa kako bismo bili sigurni da se nedostaci ne ponavljaju.



Slika 4.1. DMAIC metoda [26]

Šest sigma nudi zajednički jezik i način rješavanja poslovnih prilika i rješavanje poslovnih problema. Također pruža smjernice koje upućuju na rješenja, tj. gdje i što je potrebno sljedeće učiniti. Šest sigma dovoljno je fleksibilna da se primjenjuje za rješavanje različitih izazova u različitim organizacijskim jedinicama poduzeća kao što su proizvodnja, financije, nabava, prodaja, marketing ili bilo koje drugo funkcionalno područje. [27]

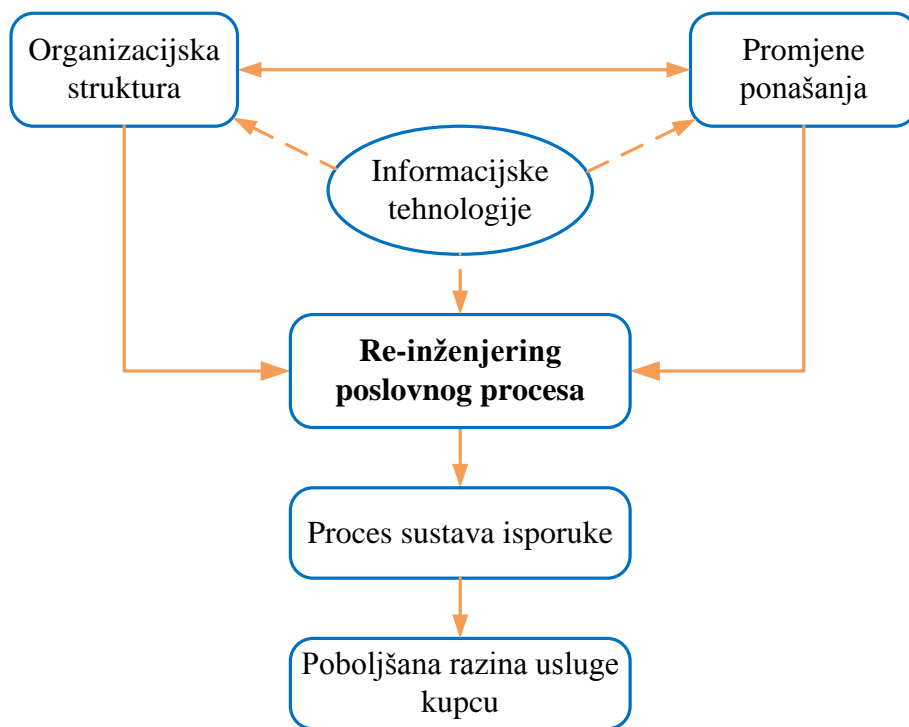
U literaturi se često spominje da se s šest sigma projektima poboljšavaju središnji poslovni procesi, dok su u stvarnosti ti projekti orijentirani na potprocese i aktivnosti. Upravo zbog toga su projekti kontinuirani i kratki (1 - 6 mjeseci). Ako nakon prve iteracije nije postignuta željena razina kvalitete, poboljšanje se nastavlja sve dok stanje ne bude odgovaralo definiranim mjerama. [23]

S obzirom na to da koncept šest sigma, sam po sebi, zahtijeva znatna financijska sredstva koja je potrebno uložiti, mogu ga financijski opravdati samo djelatnosti u kojima se ostvaruje visoka produktivnost. Zbog toga se šest sigma uglavnom primjenjuje u djelatnostima iz

tercijarnog i kvartalnog sektora. Istraživanja iz prakse također pokazuju da male tvrtke nisu pogodne za provedbu koncepta šest sigma, jer nemaju dovoljno financijskih sredstava za provedbu takvih rješenja. Tvrtke s više od 1000 zaposlenih, kao i razne holding kompanije, a posebice multinacionalne kompanije one su u kojima takva rješenja daju pozitivne rezultate u određenim djelatnostima. [23]

4.2. Re-inženjering poslovnih procesa (e. *Business Process Re-engineering – BPR*)

Re-inženjering poslovnih procesa (e. *Business Process Re-engineering - BPR*) organizacijska je metoda kojoj je cilj radikalno redizajniranje poslovnih procesa radi postizanja znatnog poboljšanja kvalitete, cijene, usluga, vodećeg vremena, fleksibilnosti i inovativnosti. Provodi se u poduzećima koja su spremna na znatne promjene kako bi se postigla poboljšanja performansi. BPR obuhvaća cijeli proces, od ideje pa sve do izrade konačnog proizvoda. Polazište re-inženjeringa poslovnih procesa identifikacija je problema i primjena suvremene informacijske tehnologije, posebice baza podataka. Model re-inženjeringa poslovnog procesa prikazan je na slici 4.2. [28]



Slika 4.2. Re-inženjering poslovnog procesa [28]

Za uspješnu provedbu BPR-a potrebno se pridržavati sljedećih ključnih aktivnosti: [29]

- izbor strateškog procesa za redizajn
- pojednostaviti novi proces, smanjiti broj koraka, optimizirati učinkovitost
- organiziranje tima zaposlenika za svaki od procesa i koordinate pojedinih procesa
- organiziranje radnog procesa – prijenos i upravljanje dokumentima
- dodjela odgovornosti i uloga za svaki proces
- automatizirati procese s pomoću informacijskih tehnologija
- voditi procesni tim da učinkovitije upravlja radom novog procesa
- uvođenje redizajniranog procesa u organizacijsku strukturu poduzeća.

Učinkovit i dosljedan re-inženjering poslovnog procesa nije moguće provesti bez suvremene informacijske tehnologije. Osim ljudskih resursa i organizacijskih promjena, informacijska tehnologija predstavlja ključan čimbenik uspješnog BPR-a. Informacijska tehnologija primjenjuje se u svim fazama re-inženjeringa, što posebno dolazi do izražaja u definiranju poslovne strategije i poslovnih procesa. S pomoću informacijske tehnologije provodi se analiziranje strukture prevladavajućih poslovnih procesa i mjere se performanse prevladavajućih procesa. Također se dizajniraju, implementiraju i provode novi procesi tako da komunikacija među članovima projektnog tima bude što jednostavnija. [5, 28, 29]

Uvođenjem BPR-a organizacija poduzeća temelji se na procesu. Nakon obavljenog redizajna organizacije zaposlenici dobivaju šire ovlasti i orijentirani su na ispunjenje zahtjeva klijenata. Organizacijska struktura poduzeća promijenila se od hijerarhijske na horizontalnu (raspodjela podataka, bolja komunikacija između odjela, svi su podjednako odgovorni za uspjehe i neuspjehe, bolja kontrola kvalitete i sl.). [29]

BPR je moguće implementirati u različitim poduzećima (proizvodnim, uslužnim i sl.) i javnim organizacijama koje zadovoljavaju sljedeće kriterije: [29]

- minimalan broj zaposlenih 20 (najmanje 4 na rukovodećim pozicijama)
- jaka želja menadžmenta za nove načine rada i inovacije
- dobra informatička infrastruktura
- radnik mora biti visoko kvalificiran i spreman na trajno obrazovanje, što je karakteristično za mala i srednja poduzeća. [5]

Uobičajeno je trajanje projekta BPR-a od 6 do 10 mjeseci i pruža velika poboljšanja poslovnog procesa. Trajanje ovisi o vrsti poslovanja poduzeća koje se reorganizira te o tehnikama i metodama koje se pri tome primjenjuju [29]. Međutim, ukupno gledajući, proces BPR je dugotrajan, jer je prilikom donošenja odluke o njegovu provođenju potrebno uzeti u obzir činjenicu da će poduzeće biti pod utjecajem stalnih promjena. Upravo zbog dugog trajanja procesa BPR-a koji se održava u dinamičnom sustavu sasvim je jasno da je trenutak početka njegova razvoja jedan od važnih čimbenika uspjeha. Od trenutka prepoznavanja procesa BPR-a do vremena uvođenja novih modela može proći nekoliko godina. [5]

4.3. Uravnotežene kartice rezultata (e. *Balanced Scorecard* – BSC)

Uravnotežene kartice rezultata (e. *Balanced Scorecard* - BSC) osmislili su Kaplan i Norton 1992. godine. Iako su izvorno zamišljene kao sustav mjerenja, metoda BSC razvila se u sustav za strateško upravljanje i snažan komunikacijski alat. Danas uravnotežene kartice rezultata pomažu poduzećima u optimizaciji strategije i u aktivnostima upravljanja, testiranju različitih strategija te vrednovanju postignuća i promjena strategija [5, 30].

Osnovna je ideja da se primjenjuje skupina pokazatelja koji se sagledavaju iz četiri uravnotežene perspektive: [31]

- *Financijska perspektiva*

Kako izgledamo dioničarima?

- *Perspektiva kupaca*

Kako nas kupci doživljavaju?

- *Interna perspektiva*

Koje osnovne procese poduzeće treba poboljšati kako bi vlasnici i kupci bili zadovoljni?


- *Perspektiva učenja i razvoja*

Može li se nastaviti s poboljšanjima i stvaranjima novih vrijednosti?

Spomenute četiri perspektive ne eliminiraju nego podržavaju ciljeve različitih tehnika menadžmenta (poput strateškog planiranja, TQM-a, i sl.) [5]. Uravnotežene kartice rezultata u osnovi su hibridna metrika, koja prevodi misiju i strategiju organizacije u sveobuhvatni skup

mjerenih performansi koje osiguravaju okvir za strateška mjerenja i upravljanja sustavom. [32]

Shematski prikaz uravnotežene kartice rezultata prikazan je na slici 4.3.



Slika 4.3. Uravnotežene kartice rezultata [31]

Za svaku od perspektiva potrebno je odrediti strategijske ciljeve u obliku mjerljivih veličina te odrediti kritične faktore uspjeha. Mjerenje performansi na temelju strategije osigurava povratnu vezu za dinamičko podešavanje i pročišćavanje organizacijske strategije. [33]


BSC je strateški mjerni i upravljački sustav koji prevodi strategiju organizacije u sveobuhvatan niz ključnih pokazatelja poslovanja. Taj sustav povezuje sva funkcionalna područja u organizaciji sprječavajući tako uobičajenu pogrešku izoliranih ciljeva i taktičkih postupaka koji nisu direktno povezani s ostvarivanjem strategije. BSC povezuje strategiju s akcijama menadžmenta pružajući menadžerima jednostavan i jasan uvid u ključne pokazatelje poslovanja, identificirajući pri tome direktne i kvantificirane ciljeve koji se moraju postići. Na taj način menadžeri mogu lako i brzo utvrditi one organizacijske dijelove koji ne funkcioniraju u skladu s poslovnom strategijom. Oni su kandidati za proces učenja povezano uz neispunjenje očekivanih ciljeva i korekciju. [5, 33]

Jedan od najvećih atributa BSC-a je njihova primjenljivost na raznim vrstama i veličinama poduzeća. Ovaj model najbolje je primjenjivati kod proizvodnji većeg obujma, odnosno kod velikih poduzeća, iako je model moguće primijeniti i kod srednje velikih poduzeća (oko 100 zaposlenika) [34].

4.4. Cjelovito produktivno održavanje (e. *Total Productive Maintenance – TPM*)

Koncept cjelovitog produktivnog održavanja (e. *Total Productive Maintenance – TPM*) razvijen je u Japanu 60-ih godina prošlog stoljeća. Definicija TPM-a prema JIPE-u (e. *Japan Institute of Plant Engineers – JIPE*) glasi: "TPM je dizajniran kako bi se povećala učinkovitost opreme (poboljšanje ukupne učinkovitosti) uspostavom sveobuhvatnog proizvodnog održavanja sustava kroz cijeli životni vijek opreme (planiranje, uporaba, održavanje i sl.), uz sudjelovanje svih zaposlenika od najvišeg rukovodstva pa do radnika na liniji (traci), koji rade na promicanju produktivnog održavanja kroz "motivacijsko upravljanje", odnosno dobrovoljnim aktivnostima radnih skupina. [35]

Tradicionalni TPM temelji se na 5S načelima (sortiranje, slaganje, spremanje, standardiziranje i samodisciplina) i osam pratećih aktivnosti koje su uglavnom usmjerene na proaktivne i preventivne tehnike poboljšanja pouzdanosti opreme, kao što je prikazano na slici 4.4.



Slika 4.4. Tradicionalni TPM model [36]

Kod uvođenja TPM koncepta potrebno je mjeriti ukupnu učinkovitost opreme (e. *overall equipment effectiveness - OEE*), koja označava postotak planiranog vremena proizvodnje koje je doista produktivno [36].

- OEE od 100 % je savršena proizvodnja
- OEE od 85 % je vrlo dobra proizvodnja
- OEE od 60 % je uobičajena proizvodnja
- OEE od 40 % je uobičajena za proizvodnje bez TPM-a ili vitkih programa.

Ukupna učinkovitost opreme (izraz 3.4) sastoji se od tri temeljna pokazatelja koji uzimaju u obzir različite vrste gubitaka produktivnosti (dostupnost, učinkovitost i kvaliteta) koje su opisane u poglavlju 3.4.1.

Osnovni ciljevi koji se žele postići uvođenjem TPM koncepta jesu sljedeći: [35]

- razvoj i humanizacija rada, povećanje važnosti zaposlenika
- čistoća, red i disciplina na radnim mjestima
- kontinuirano poboljšanje postojećeg načina rada
- davanje najveće važnosti postizanju zadovoljstva kupca
- učiniti sve u pravo vrijeme i činiti to u svako vrijeme.

Na osnovi navedenog može se reći da se TPM pristupom održavanja opreme nastoji postići savršena proizvodnja: bez kvarova, zastoja i loših proizvoda, naravno uz sigurno radno okruženje – bez nezgoda. TPM naglašava proaktivno i preventivno održavanje kako bi se povećala operativna učinkovitost opreme. Preventivno održavanje oslanja se na osoblje za održavanje, TPM uključuje operatere u redovito održavanje, poboljšanje projekta i sitne popravke (kao što su: podmazivanje, čišćenje, zatezanje i inspekcija opreme) [37]. Provedbom TPM programa stvara se zajednička odgovornost za opremu koja potiče veću uključenost radnika, a to može dovesti do znatnog poboljšanja produktivnosti (smanjenje radnih ciklusa, otklanjanje nedostataka i sl.). [20, 36]

4.5. Potpuno upravljanje kvalitetom (e. *Total Quality Management – TQM*)

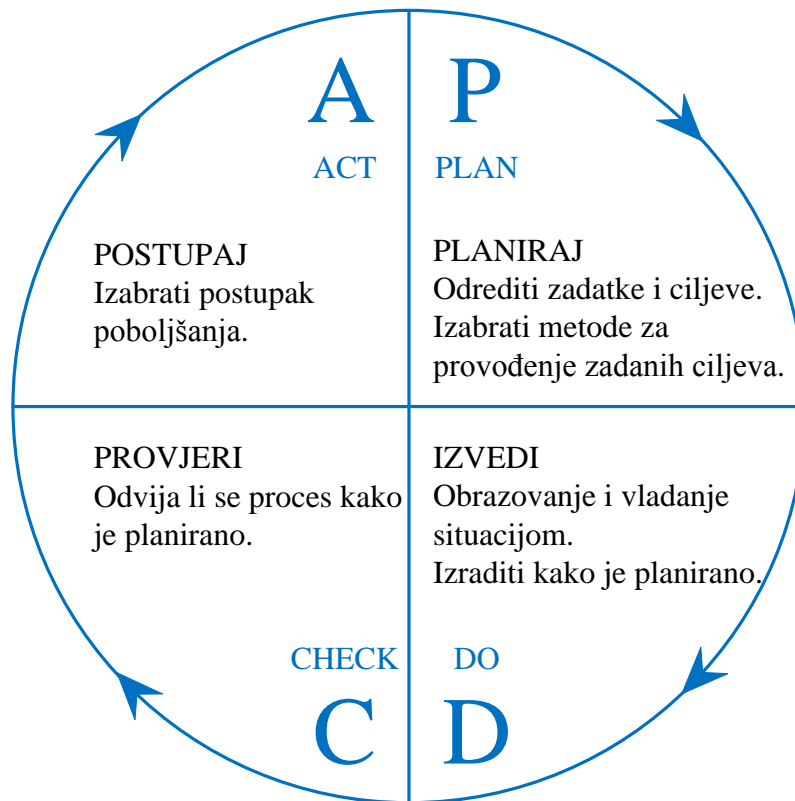
U početku, upravljanje kvalitetom svodilo se na sortiranje prihvatljivih i neprihvatljivih proizvoda. Kasnije, upravljanje kvalitetom uključuje koncept kontrole kvalitete (e. *quality control - QC*), koji se ističe u kontroli praćenja procesa s alatima poput kontrolnih karti i uzrokovanja. Osiguranje kvalitete (e. *quality assurance - QA*) sljedeći je korak u upravljanju kvalitetom i fokusiran je na ispunjavanje zahtjeva kupaca poboljšanjem kontrole procesa. Konačno, koncept potpunog upravljanja kvalitetom (e. *Total Quality Management – TQM*) uključuje sve sudionike u proizvodnji roba i usluga radi postizanja zahtjeva kupaca. [24]

Potpuno upravljanje kvalitetom sustav je poboljšanja, povećanja fleksibilnosti, učinkovitosti i uspješnosti poslovanja poduzeća. Temelji se na konceptu stalnog razvoja i unaprjeđenja procesa, na trajnoj kvaliteti i timskom radu, što rezultira kontinuiranim poboljšanjem. Uglavnom, TQM se fokusira na tri glavna načela: [5]

- usredotočenost na zadovoljstvo kupca
- postizanje trajnog i održivog poboljšanja procesa i rezultata
- osigurava punu predanost zaposlenika za poboljšanje kvalitete.

Osnova TQM-a je potpuna kvaliteta, koja mora biti konstantna u sustavu dodavanja vrijednosti proizvodu ili usluzi kako s gledišta korisnika, tako i s gledišta menadžmenta. Stalnu kvalitetu potrebno je pružiti uz najniže troškove, odnosno uz najbolju upotrebu materijalnih i ljudskih resursa. TQM u potpunosti mijenja radnu organizaciju, odnos zaposlenika i menadžmenta te odnos s kupcem – potrošačem. [5, 38]

TQM djeluje kroz primjenu tehnika i postupaka koji se primjenjuju za smanjenje ili uklanjanje razlike u proizvodnim procesima roba i usluga, poboljšanje učinkovitosti, pouzdanosti i kvalitete [24]. TQM metoda oslanja se na ciklus upravljanja procesima *planiraj-izvedi-provjeri-postupaj - PDCA* (e. *Plan-Do-Check-Act - PDCA*), kao što je prikazano na slici 4.5.



Slika 4.5. PDCA krug [5]

Kao ključni elementi potpunog upravljanja kvalitetom navode se: [38]

- predanost i vodstvo od strane vrhovnog menadžmenta
- planiranje i organizacija procesa poboljšanja
- primjena alata i tehnika kao podrška procesu poboljšanja
- obrazovanje i osposobljavanje zaposlenika za proces kontinuiranog poboljšanja
- uključenost svih zaposlenika u proces
- timski rad
- mjerenje pokazatelja rezultata i povratne informacije
- sigurnost da organizacijska kultura pridonosi aktivnostima kontinuiranog poboljšanja.


Sam postupak uvođenja TQM-a sveobuhvatan je i dugoročan proces. Vodstvo poduzeća mora održavati svoju predanost provedbi projekta, pružati potrebnu podršku zaposlenicima i tražiti odgovornost za izvršene zadatke. Isto tako TQM je snažna tehnika za poticanje kreativnosti i potencijala zaposlenika, smanjenje troškova, te poboljšanje usluge klijentima [39]. Metoda TQM često se primjenjuje u serijskoj i masovnoj proizvodnji, gdje je proizvodnja automatizirana, a dijelovi standardizirani [5].

4.6. 20 ključeva (e. 20 keys)

Metodologiju 20 ključeva (e. 20 keys) razvio je Iwao Kobayashi, a temelji se na *Toyotinu* proizvodnom sustavu (e. *Toyota Production System*). Često upotrebljavan naziv za 20 ključeva jest "praktični program revolucije u tvornicama" (e. *The Practical Programme of Revolution in Factories – PPORF*). [40]

Metodologija 20 ključeva predstavlja 20 područja u kojima se poduzeće može kontinuirano unaprjeđivati. [40] To je sveobuhvatan program neprekidnog unaprjeđenja poslovanja, koji uključuje sve zaposlenike tvrtke. Metodologija je primjenljiva u svim djelatnostima, a ne samo u proizvodnim tvrtkama, ali se ne primjenjuje u tvrtkama kojima je potrebno temeljito restrukturiranje, nego u onim au kojima je potrebno poboljšanje postojećih procesa.

U metodologiji 20 ključeva ključevi su raspoređeni kao na slici 4.6, koja pokazuje odnose između ključeva i njihov utjecaj na tri glavna faktora: kvalitetu, troškove i vodeće vrijeme. Raspored u krugu nije kategoričan, a prednosti nekih od ključeva odnose se na više faktora. [21]




Slika 4.6. 20 ključeva za poboljšanje procesa [41]

Značenje pojedinih ključeva navedeno je u tablici 4.3., u kojoj su također i navedeni ciljevi ključeva te koji ključevi doprinose postizanju ciljeva, poput: jačanje radnog mjesta, poboljšanje kvalitete, smanjenje troškova (povećanje produktivnosti), poboljšanje toka procesa te razvoj tehnologije. Na slici 4.6 vidi se da su četiri ključa izvan kruga. Tri od njih (1, 2 i 3) moraju biti provedeni prije ostalih, dok je ključ 20 rezultat provedbe prethodnih 19 ključeva. [42]

Tablica 4.3. Značenje i ciljevi 20 ključeva [42]

Cilj	20 ključeva
Jačanje radnog mjesta	1 Čišćenje i organiziranje 2 Racionalizacija sustava / razvrstavanje ciljeva 3 Aktivnosti malih grupa 10 Kontrola vremena i predanost
Poboljšanje kvalitete	7 Proizvodnja s nula defekata 9 Održavanje strojeva i opreme 11 Osiguranje kvalitete 12 Razvijanje dobavljača 15 Raznovrsnost vještina i obuke
Smanjenje troškova (poboljšanje produktivnosti)	13 Uklanjanje otpada 14 Ohrabrivanje zaposlenika da stvaraju poboljšanja 6 Kaizen poslovanja 17 Kontrola učinkovitosti 19 Štednja energije i materijala
Poboljšanje toka procesa, brže isporuke	5 Brza promjena postupaka 4 Smanjivanje zaliha 16 Raspoređivanje proizvodnje 8 Povezana proizvodnja
Razvoj tehnologije	18 Primjena mikroprocesora 20 Primjena tehnologije za stratešku prednost

Metodologija 20 ključeva provodi se tako što je svaki ključ podijeljen na pet razina uz postavljene kriterije za prelazak iz jedne na drugu razinu. Prvi korak metodologije određivanje je trenutne razine tvrtke, a zatim razine koju tvrtka želi postići. Nakon što je definirana trenutna razina tvrtke, definiraju se koraci kojima se postupno dolazi do konačnog cilja (razine koju se želi postići). Za prikaz razvoja tvrtke i bodovanje svakog od ključeva upotrebljava se tzv. "radar-grafikon", kao što je prikazano na slici 4.7. [40]



Slika 4.7. Radar-grafikon [41]

Ciljevi su metodologije:

- ostvariti strateške ciljeve poslovanja na učinkovit način
- unaprijediti brzinu učenja i inovacija u poslovanju
- povećati produktivnosti i skratiti vremenske cikluse proizvodnje
- motivirati zaposlenike na kontinuirano poboljšanje
- unaprijediti konkurentnost, profitabilnost i dugoročni održivi uspjeh kompanije.

Važan je aspekt 20 ključeva sinergijski učinak između različitih ključeva. Metodologija 20 ključeva uravnotežena je tako da naponi koji su učinjeni za jedan ključ imaju svoj utjecaj na nekoliko drugih ključeva. To je razlog zašto se ne mora početi sa svih 20 ključeva u isto vrijeme kako bi se postigli rezultati. [21]

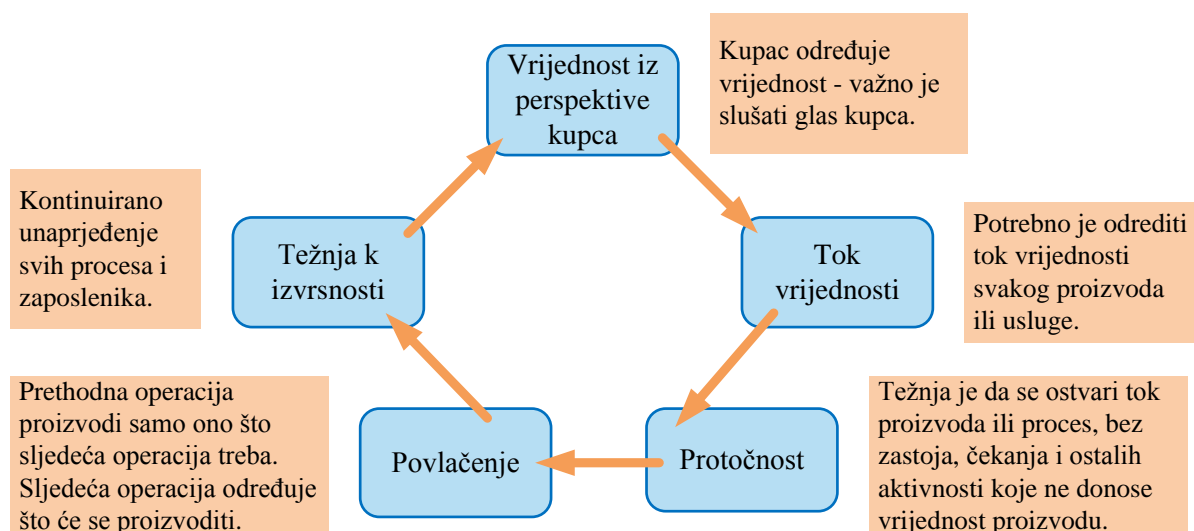
4.7. Vitka proizvodnja (e. *Lean production*)

Termin vitka proizvodnja definirali su Womak, Jones i Ross 1990. godine [11]. Vitka proizvodnja filozofija je koja izvorno potječe iz *Toyotina* proizvodnog sustava. Usredotočena je na skraćivanje vremena od narudžbe kupca do isporuke gotovog proizvoda ili pružanja

usluge koje zadovoljavaju narudžbu. Kako bi se poboljšala učinkovitost, djelotvornost i profitabilnost, potrebno se usredotočiti na uklanjanje gubitaka iz procesa, odnosno svega onog što ne dodaje vrijednost proizvodu ili usluzi. Načela su vitke proizvodnje timski rad, komunikacija, učinkovita primjena resursa i stalno poboljšanje. [26, 43]

Prema autorima Marchwinski i Shook (2004) vitka proizvodnja sustav je za organiziranje i upravljanje razvojem proizvoda, poslovanjem, dobavljačima i odnosima s kupcima koji zahtijeva manje ljudskog napora, prostora, kapitala, materijala i manje vremena za proizvodnju proizvoda s manje grešaka prema želji kupca u odnosu na prethodni sustav masovne proizvodnje [11].

Vitki (e. *lean*) koncept uključuje i stratešku i operativnu razinu poslovanja. Na strateškoj razini gleda se što donosi vrijednost proizvodu i kako se ona povećava, a također se gleda na proizvodnju kao proces i teži savršenstvu. Kada se vitki koncept promatra s operativne razine, onda se misli na primjenu raznolikih alata i tehnika za primjenu ovog koncepta u svakodnevnom poslovanju. Osnovna ideja postizanja vitke proizvodnje načelo je kontinuiranog smanjenja gubitaka, odnosno svih aktivnosti koje ne doprinose uspješnom poslovanju poduzeća, a time ni ne dodaju vrijednost proizvodu ili usluzi. Vitki menadžment najlakše je opisati kroz njegovih pet osnovnih načela: vrijednosti iz perspektive kupca, toka vrijednosti, protočnosti, povlačenja i težnje k izvrsnosti. Ova načela su prikazana na slici 4.8. [44]



Slika 4.8. Principi vitkog menadžmenta [45]

U nastavku su ukratko opisani glavni gubici prema vitkoj proizvodnji i protumjere za smanjenje ili eliminaciju gubitaka, kao i temeljni alati koji se upotrebljavaju za provedbu vitke proizvodnje. Također su navedeni i ključni čimbenici implementacije vitke proizvodnje.

4.7.1. Vrste gubitaka

Prema tradicionalnoj vitkoj proizvodnji postoji sedam vrsta gubitaka u poslovanju poduzeća, a to su: prekomjerna proizvodnja, zalihe, transport, čekanje, nepotrebna kretanja, škart i prekomjerna obrada. Iznimno važan oblik gubitka koji nije naveden u osnovnih sedam vrsta gubitaka nedovoljna je primjena potencijala radnika. Taj oblik gubitka predstavlja gubitke zbog izgubljenih prilika (npr. zbog smanjene motivacije, kreativnosti, ideja i sl.). Jedan od razloga zašto se taj gubitak često umanjuje ili ignorira u poduzeću je to, što je odgovornost za taj gubitak upravo na menadžmentu poduzeća. Neiskorišteni ljudski potencijali često su rezultat politike upravljanja i upravljačkih stilova koji umanjuju doprinos zaposlenika. Navedeni gubici opisani su u tablici 4.4, zajedno s predloženim protumjerama za smanjenje ili eliminaciju gubitaka. [36]

Tablica 4.4. Vrste gubitaka prema vitkoj metodologiji, opis i protumjera (vitki alat) [36]

Vrsta gubitka	Opis	Protumjera (vitki alat)
Prekomjerna proizvodnja (e. <i>Over-production</i>)	Izrada nečega prije nego što je uistinu potrebno. To je ozbiljan problem otpada, jer dovodi do viška zaliha koje se često upotrebljavaju za prikrivanje temeljnih problema i neučinkovitosti.	<ul style="list-style-type: none"> • Uskladiti stopu proizvodnje sa stopom potražnje kupaca (<i>Taktno vrijeme</i>). • Primijeniti sustav povlačenja za kontrolu koliko je proizvedeno (<i>Kanban</i>). • Smanjiti vrijeme podešavanja, tako da je proizvodnja u manjim serijama ekonomski prihvatljiva (<i>SMED</i>).
Zalihe (e. <i>Inventory</i>)	Količine proizvoda (sirovina, obradaka, gotovih proizvoda) koji premašuju količine trenutnih potreba.	<ul style="list-style-type: none"> • Dostava samo onih sirovina za koje postoji potreba (<i>U-pravo-vrijeme</i>). • Smanjenje ili eliminiranje međuzaliha između proizvodnih operacija (<i>Kontinuirani tok</i>). • Protumjere prekomjerne proizvodnje (<i>Taktno vrijeme, Kanban, SMED</i>).

Tablica 4.4. Vrste gubitaka prema vitkoj metodologiji, opis i protumjera (vitki alat) [36] - nastavak

Vrsta gubitka	Opis	Protumjera (vitki alat)
Transport (e. <i>Transport</i>)	Nepotrebno kretanje sirovina, obradaka ili gotovih proizvoda.	<ul style="list-style-type: none"> • Oblikovati linearni, sekvencijalni tijek od sirovina do gotovih proizvoda (<i>Mapiranje toka vrijednosti</i>). • Uvjeriti se da se ne proizvodi za "svaki slučaj" (<i>Kontinuirani tok</i>). • Izbjegavati stalno mijenjanje prioriteta posla (<i>Teorija graničnih uvjeta</i>).
Čekanje (e. <i>Waiting</i>)	Vrijeme kada se u procesu proizvodnje čeka na sljedeći korak u proizvodnji (nema dodavanja vrijednosti proizvodu). Razmatrajući vrijeme od narudžbe do isporuke, pitamo se koliko je stvarno vrijeme proizvodnje s dodavanjem vrijednosti proizvodu.	<ul style="list-style-type: none"> • Projektirati procese tako da je tijek procesa kontinuiran, s minimalnim zastojsima ili bez njih između proizvodnih operacija (<i>Kontinuirani tijek</i>). • Upotrijebiti standardizirane radne upute kako bi se osigurao dosljedan način i vrijeme za obavljanje proizvodnih operacija (<i>Standardizirani rad</i>).
Nepotrebna kretanja (e. <i>Motion</i>)	Nepotrebno kretanje ljudi (pokreti koji ne dodaju vrijednost) ili opreme.	<ul style="list-style-type: none"> • Osigurati da područje rada bude logično organizirano (<i>5S</i>). • Razmisliti o zamjenskim rješenjima opreme kojima se smanjuju kretanja (<i>Mapiranje toka vrijednosti</i>).
Škart (e. <i>Defects</i>)	Proizvodnja loših proizvoda ili proizvoda koji zahtijevaju ponovnu obradu.	<ul style="list-style-type: none"> • Projektirati procese s manjom vjerojatnošću za proizvodnju grešaka (<i>Poka-Yoke</i>). • Projektirati procese s otkrivanjem grešaka, tako da se mogu odmah ispraviti (<i>Jidoka</i>). • Pronaći najčešći kvar i utvrditi zašto se javlja (<i>Temeljita analiza uzroka</i>). • Stvaranje radnih uputa koje pružaju dosljedan način proizvodnje (<i>Standardizirani rad</i>).
Prekomjerna obrada (e. <i>Over-processing</i>)	Više obrade nego što je potrebno za proizvodnju onoga što kupac želi. Često je taj gubitak teško otkriti i eliminirati.	<ul style="list-style-type: none"> • Usporediti zahtjeve kupaca s proizvodnim mogućnostima (<i>Kaizen</i>). • Potražiti potencijalna pojednostavnjenja procesa proizvodnje (<i>Kaizen</i>).

Tablica 4.4. Vrste gubitaka prema vitkoj metodologiji, opis i protumjera (vitki alat) [36] - nastavak

Vrsta gubitka	Opis	Protumjera (vitki alat)
Nedovoljna primjena potencijala radnika (e. <i>Unused Human Potential</i>)	Gubici zbog izgubljenih prilika (npr. zbog smanjene motivacije, kreativnosti, ideja i sl.). Loša politika zapošljavanja. Loše rukovođenje i hijerarhijska struktura.	<ul style="list-style-type: none"> • Uključivati radnike u aktivnosti poboljšanja procesa, razvoj kreativnosti zaposlenika, njihovo fokusiranje na određene radne zadatke s ciljem poboljšanja kvalitete rada i eliminacije rasipanja (<i>Kaizen</i>).

4.7.2. Alati i tehnike vitke proizvodnje

Vitka proizvodnja ima vrlo opsežan skup alata i tehnika. Istraživanje najvažnijih od njih, razumijevanje onoga što su oni i kako pridonose poboljšaju poslovanja poduzeća, odlične su smjernice prema vitkom poduzeću. U tablici 4.5 navodi se pregled najvažnijih vitkih alata s kratkim opisom i objašnjenjem kako oni pridonose poboljšanju proizvodnih operacija.

Tablica 4.5. Temeljni alati i tehnike vitke metodologije [36]

Vitki alat	Što je?	Kako pomaže?
5S (e. <i>5S</i>)	Organizira radni prostor: <ul style="list-style-type: none"> • Sortiranje (odvajanje potrebnih od nepotrebnih alata i dijelova) • Slaganje (spremanje preostalih potrebnih alata prema tome kako će se upotrijebiti) • Spremanje (održavanje čistog i urednog radnog mjesta) • Standardiziranje (osigurava da se svi zaposlenici drže načela sortiranja, slaganja i spremanja) • Samodisciplina (održavanje uvedenog principa sve dok ne prijeđe u rutinu) 	Eliminira gubitke koji nastaju u slabo organiziranom radnom mjestu (npr. gubitak vremena u potrazi za alatom).

Tablica 4.5. Temeljni alati i tehnike vitke metodologije [36] - nastavak

Vitki alat	Što je?	Kako pomaže?
Andon (e. <i>Andon</i>)	Vizualni sustav povratnih informacija proizvodnog pogona koji označava stanje proizvodnje. Upozorava kada je potrebno djelovanje operatera koji imaju ovlasti za zaustavljanje procesa proizvodnje.	Djeluje kao komunikacijski alat proizvodnog pogona u stvarnom vremenu koji upućuje na probleme čim se pojave – tako da se oni mogu odmah rješavati.
Analiza uskog grla (e. <i>Bottleneck Analysis</i>)	Određuje koji dio proizvodnog procesa ograničava ukupnu propusnost te poboljšava učinkovitost tog dijela procesa.	Poboljšava propusnost jačanjem najslabije karike u procesu proizvodnje.
Kontinuirani tok (e. <i>Continuous Flow</i>)	Proizvodnja u kojoj se proces odvija glatko uz minimalne zalihe (ili bez zaliha) između operacija proizvodnog procesa.	Uklanja mnoge oblike gubitaka (npr. zalihe, vrijeme čekanja, transport).
Gemba (stvarno mjesto) (e. <i>Gemba (The Real Place)</i>)	Filozofija koja podsjeća na odlazak iz ureda u proizvodni pogon – mjesto gdje se događa stvarna radnja.	Promiče duboko i temeljito razumijevanje stvarnih proizvodnih pitanja – od promatranja iz "prve ruke" i razgovora sa zaposlenicima iz proizvodnog pogona.
Heijunka (nivo planiranja) (e. <i>Heijunka (Level Scheduling)</i>)	Oblik rasporeda proizvodnje u kojem se namjerno proizvodi u malim serijama, kombiniranjem različitih proizvoda unutar istog procesa.	Smanjuje vodeće vrijeme (svaki se od proizvoda češće proizvodi) i zaliha (budući da su manje serije).
Hoshin Kanri (Politika implementacije) (e. <i>Hoshin Kanri (Policy Deployment)</i>)	Usklađivanje ciljeva tvrtke (strategije) s planovima srednjeg menadžmenta (taktika) i obavljanja rada u proizvodnom pogonu (akcija).	Osigurava dosljedan i temeljit napredak prema strateškim ciljevima, kroz eliminaciju gubitaka koji dolaze iz loše komunikacije i nekonzistentnog smjera.
Jidoka (automatizacija) (e. <i>Jidoka (Autonomation)</i>)	Projektiranje opreme za djelomičnu automatizaciju procesa proizvodnje (djelomična automatizacija je obično znatno jeftinija od potpune automatizacije) i automatsko zaustavljanje kada su otkriveni nedostaci.	Nakon uvođenja Jidoka, radnici mogu nadzirati rad više radnih stanica (smanjenje troškova rada), a problemi u kvaliteti mogu se odmah otkriti (poboljšanje kvalitete).

Tablica 4.5. Temeljni alati i tehnike vitke metodologije [36] - nastavak

Vitki alat	Što je?	Kako pomaže?
U pravo vrijeme (e. <i>Just-In-Time (JIT)</i>)	Povlačenje dijelova kroz proizvodnju temeljene na zahtjevu kupca, umjesto guranja dijelova kroz proizvodnju na osnovi potražnje. Oslanja se na vitke alate kao što su: kontinuirani tok, Heijunka, Kanban, standardizirani rad, taktno vrijeme.	Visoko učinkovit u smanjenju razine zaliha. Poboljšava tok novaca i smanjuje potreban prostor.
Kaizen (kontinuirano poboljšanje) (e. <i>Kaizen (Continuous Improvement)</i>)	Strategija gdje zaposlenici zajedno i aktivno rade na postizanju redovitih dodatnih poboljšanja procesa proizvodnje.	Kombinira talente tvrtke u svrhu kontinuiranog poboljšanja poslovanja uklanjanjem gubitaka iz proizvodnog procesa.
Kanban (sustav povlačenja) (e. <i>Kanban (Pull System)</i>)	Način reguliranja toka robe unutar tvornice, te s vanjskim dobavljačima i kupcima. Temelji se na automatskom nadopunjavanju putem signalnih kartica koje upozoravaju kada je potrebno više robe.	Smanjuje gubitke zaliha i prekomjerne proizvodnje. Može eliminirati potrebu za fizičkim zalihama (oslanjajući se na signalne kartice koje upozoravaju kada je potrebno naručiti robu).
KPI (ključni indikatori performansi) (e. <i>KPI (Key Performance Indicator)</i>)	Metrika osmišljena za praćenje i poticanje napretka prema ključnim ciljevima organizacije. Snažno promoviranje KPI može biti izuzetno jak pokretač ponašanja – stoga je potrebno pažljivo odabrati KPI.	Najbolji proizvodni KPI: <ul style="list-style-type: none"> • Usklađeni su sa strateškim ciljevima (čime pomažu u postizanju tih ciljeva). • Učinkoviti su u otkrivanju i kvantificiranju gubitaka (OEE je dobar primjer). • Brzo utječu na zaposlenike proizvodnog pogona (kako bi mogli postići rezultate).
Muda (gubici) (e. <i>Muda (Waste)</i>)	Sve što u proizvodnom procesu, iz perspektive kupca, ne dodaje vrijednost proizvodu.	Eliminacija gubitaka primarni je fokus vitke proizvodnje.
Ukupna učinkovitost opreme (e. <i>Overall Equipment Effectiveness (OEE)</i>)	Okvir za mjerenje gubitaka produktivnosti za određeni proizvodni proces. Prate se tri kategorije gubitaka: <ul style="list-style-type: none"> • Dostupnost (npr. zastoji) • Učinak (npr. sporost ciklusa) • Kvaliteta (npr. odbacivanja). 	Pruža referentnu baznu liniju (osnovicu) i sredstva za praćenje napretka u smanjenju gubitaka procesa proizvodnje. 100 % OEE znači savršenu proizvodnju (izrada samo dobrih dijelova, što je brže moguće, bez zastoja).

Tablica 4.5. Temeljni alati i tehnike vitke metodologije [36] - nastavak

Vitki alat	Što je?	Kako pomaže?
PDCA (planiraj, izvedi, provjeri, postupaj) (e. <i>PDCA (Plan, Do, Check, Act)</i>)	Iterativna metoda za provedbu poboljšanja: <ul style="list-style-type: none"> • Planiraj (uspostavi plan i planirane zadatke) • Izvedi (provedi plan) • Provjeri (provjeri postignute rezultate) • Postupaj (pregled i procjena; ponovi) 	Odnosi se na znanstveni pristup poboljšanju: <ul style="list-style-type: none"> • Planiraj (razvijanje hipoteze) • Izvedi (izvedba eksperimenta) • Provjeri (ocjena rezultata) • Postupaj (dorada eksperimenta, pokušaj ponovno)
Poka-Yoke (Izbjegavanje pogreške) (e. <i>Poka-Yoke (Error Proofing)</i>)	Projektiranje otkrivanja pogrešaka i sprječavanje pojavljivanja u proizvodnom procesu, radi postizanja proizvodnje bez grešaka.	Teško je (i skupo) pronaći sve nedostatke putem kontrole, a ispravljanje grešaka je obično znatno skuplje sa svakom sljedećom fazom proizvodnje.
Analiza uzroka (e. <i>Root Cause Analysis</i>)	Rješavanje problema metodologijom koja se fokusira na rješavanje temeljnih problema umjesto primjene brzih popravaka kojima se rješavaju samo simptomi problema. Zajednički pristup je pitati se pet puta zašto – svaki zašto korak je bliže otkrivanju pravog temeljnog problema.	Pomaže da se uzrok problema doista eliminiira primjenom korektivne mjere.
Brza izmjena alata (e. <i>Single Minute Exchange of Die (SMED)</i>)	Smanjenje vremena podešavanja (zamjene) na manje od 10 minuta. Metoda uključuje: <ul style="list-style-type: none"> • Mogućnost podešavanja u radu • Pojednostavnjenje montaže • Eliminiranje nebitnih operacija • Izrada standardiziranih uputa za rad 	Omogućuje proizvodnju u manjim količinama, smanjuje zalihe te poboljšava prilagodbe zahtjevima kupca.
Šest velikih gubitaka (e. <i>Six Big Losses</i>)	Šest uobičajenih kategorija gubitaka proizvodnje: <ul style="list-style-type: none"> • Kvarovi • Montaža / podešavanja • Kratka zaustavljanja • Smanjenje brzine proizvodnje • Gubici uhodavanja • Proizvodni gubici 	Pruža okvir za djelovanje na najčešće uzroke gubitaka u proizvodnji.

Tablica 4.5. Temeljni alati i tehnike vitke metodologije [36] - nastavak

Vitki alat	Što je?	Kako pomaže?
SMART ciljevi (e. <i>SMART Goals</i>)	Ciljevi su: specifični, mjerljivi, dostižni, relevantni i vremenski određeni.	Pomaže osigurati učinkovitost ciljeva.
Standardizirani rad (e. <i>Standardized Work</i>)	Dokumentirani postupci za proizvodnju koji obuhvaćaju dobru praksu (uključujući i vrijeme potrebno za završetak svakog zadatka). Dokumentacija se mora moći lako mijenjati.	Uklanja gubitke dosljedno primjenjujući najbolje prakse. Čini osnovu za buduće aktivnosti poboljšanja.
Taktno vrijeme (e. <i>Takt Time</i>)	Tempo proizvodnje (npr. proizvodnja jednog komada svakih 34 sekunde) koje usklađuje proizvodnju sa zahtjevima kupaca. Računa se kao planirano vrijeme proizvodnje / zahtjevi kupaca.	Osigurava jednostavan i dosljedan tempo proizvodnje. Primjenljiv na ciljeve proizvodnje (stvarni komadi / ciljani komadi).
Cjelokupno produktivno održavanje (TPM) (e. <i>Total Productive Maintenance (TPM)</i>)	Cjelovit pristup održavanju koji se fokusira na proaktivno i preventivno održavanje kao bi se povećalo operativno vrijeme opreme. TPM naglašava razliku između održavanja i proizvodnje s poticanjem operatera na održavanje opreme.	Stvara zajedničku odgovornost za opremu poticanjem veće uključenosti radnika proizvodnog pogona. U dobrom okruženju to može biti vrlo učinkovito i dovodi do poboljšanja produktivnosti (smanjenje radnih ciklusa, otklanjanje nedostataka).
Mapiranje toka vrijednosti (e. <i>Value Stream Mapping</i>)	Alat se primjenjuje za vizualizaciju tijeka proizvodnje. Prikazuje sadašnje i buduće stanje procesa tako da ističe mogućnosti za poboljšanje.	Izlaže gubitke u sadašnjem procesu i pruža smjernice za poboljšanje u budućem stanju.
Vizualizacija tvornice (e. <i>Visual Factory</i>)	Vizualni pokazatelji koji pokazuju kontrolne točke proizvodnog pogona radi poboljšanja komunikacije i razmjene informacija.	Omogućuje svima pregled i stanje proizvodnog procesa lako dostupnim i vrlo jasnim.

Navedeni alati mogu se uspješno primijeniti pojedinačno, a isto je tako moguće istovremeno primijeniti više alata jer se međusobno podržavaju i nadopunjavaju jedni druge [36].

4.7.3. Implementacija vitke proizvodnje

Provedba vitke metodologije može se opisati kao skup radnji i postupaka koji uključuju planiranje promjena, definiranje čimbenika uspjeha te provedbu i mjerenje napretka. Kod implementacije vitke metodologije zahtijeva se uspostava okruženja u kojem je moguće provesti navedene radnje i postupke. Alati i tehnike vitke metodologije jesu važni, ali je osnovno načelo Toyotina proizvodnog sustava, iz kojeg potječe i vitka proizvodnja, da su zaposlenici najvažnija vrijednost poduzeća. Zbog toga se menadžment mora fokusirati na zaposlenike kako bi se utvrdili zadaci koji ne dodaju vrijednost te poticalo kontinuirano poboljšanje sustava primjenom vitkih načela, alata i tehnika.

Ključni čimbenici uspjeha kod provedbe vitke metodologije jesu: [11]

- *Pokrenuti vitke promjene*
 - Zadovoljiti očekivanja zainteresiranih strana.
 - Voditi promjene: motivirati, poticati, prevladavati prepreke kod promjena i odrediti nosioce promjena u skladu sa strategijom.
- *Ciljeve i inicijative uskladiti sa strategijom*
 - Odrediti prirodu i opseg promjena, kritičnih nedostataka.
 - Definiranje strateških ciljeva i inicijativa.
 - Uspostaviti parametre uspješnosti.
- *Definirati (projektirati, dizajnirati) proces promjena*
 - Projektne varijante procesa.
 - Popis potrebnih mjera s ključnim točkama.
- *Usklađenje organizacije*
 - Organizacijska struktura.
 - Unutarnja organizacija (sustavi, politike i procedure).
 - Vještine, sposobnosti i resursi (financijski, ljudski, materijalni).
- *Organizacijsko učenje*
 - Poticanje kontinuiranog obrazovanja i usavršavanja
 - Upravljanje inovacijama / znanjem i vještinama.

Kao i drugi sustavi upravljanja tako i vitka metodologija ima nedostataka uključujući moguće probleme poput: nezadovoljstva korisnika, troškova proizvodnje, problema opskrbe, visokih troškova provedbe te neprihvatanje od strane zaposlenika. Jedan je od glavnih razloga

neuspješne provedbe vitke metodologije ponašanje zaposlenika koji izražavaju nepovjerenje i odbojnost prema novim načinima rada. Za uspješnu provedbu vitke metodologije potrebno je aktivno sudjelovanje svih zaposlenika. [46]

Učinci primjene vitke metodologije: [44]

- ukupno vrijeme proizvodnje skraćuje se
- povećava se radni učinak
- smanjuju se zalihe
- poboljšava se kvaliteta
- skraćuje se vrijeme plasiranja proizvoda na tržište
- manji prostorni zahtjevi
- manja ulaganja u skladišne kapacitete
- brži odgovor na tržišne promjene
- pojednostavnjuje se funkcija planiranja i smanjuje dokumentacija poslovanja.

Vitku metodologiju (vitki način upravljanja) moguće je primijeniti u svim vrstama proizvodnih poduzeća (od malih do velikih te bilo koje vrste proizvodnje), uslužnim djelatnostima (pošta, vladine institucije, svi administrativni odjeli u proizvodnim poduzećima, nabava, računovodstvo i sl.), bolnicama i zdravstvu općenito, sveučilištima, građevinarstvu i sl. [43, 44]

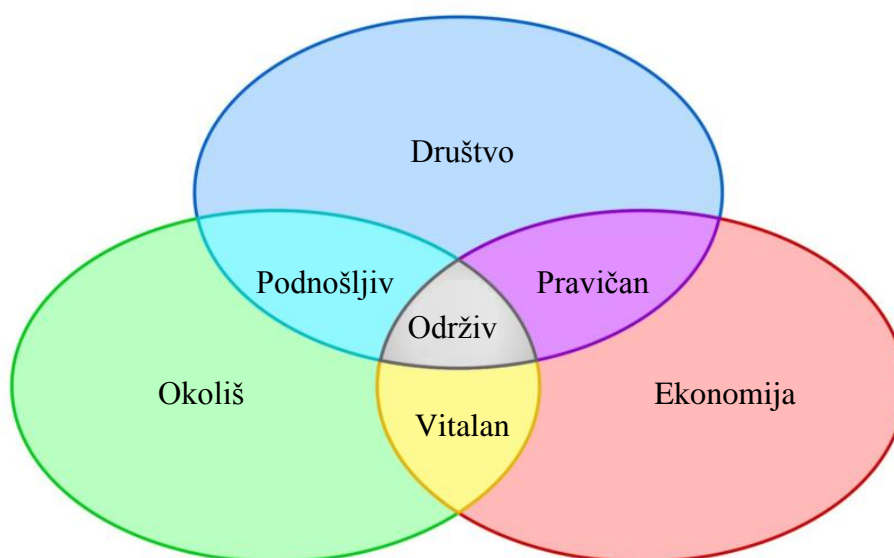
4.8. Zelena proizvodnja (e. *Green production*)

Proizvodne aktivnosti značajan su izvor utjecaja na okoliš jer su mnogi procesi energetske intenzivni. Iskustvo pokazuje da se znatan dio potrošnje energije u mnogim proizvodnim operacijama odnosi na način kako je to učinjeno (upravljanje), a ne na ono što je učinjeno (proces). Jednostavnim promjenama u procesu proizvodnje može se povećati energetska učinkovitost, odnosno smanjiti ukupna potrošnja s malo ulaganja ili bez kapitalnih ulaganja. [47]

Kod zelene proizvodnje smanjenje štetnih utjecaja na okoliš jednako je važno kao i druge tradicionalne mjere, kao što su cijena, kvaliteta i brzina. To znači da organizacija obuhvaća kontinuirano poboljšanje utjecaja na okoliš u svim poslovnim funkcijama. Također

podrazumijeva da je sprječavanje onečišćenja jedini razuman pristup smanjenju štetnog utjecaja na okoliš. Primarni otpad koji je predmet zelenog proizvodnog sustava uključuje: opasne tvari, stakleničke plinove, kruti otpad, potrošnju vode i energije. [48]

Smanjenje štetnog utjecaja na okoliš glavna je zadaća zelene proizvodne strategije. Važno je postići održivi razvoj koji zadovoljava potrebe sadašnjosti bez ugrožavanja mogućnosti da i buduće generacije zadovolje vlastite potrebe. Održivi je razvoj proces promjena u kojem su iskorištavanje resursa, smjer ulaganja, orijentacija tehničkog razvoja i institucionalne promjene u međusobnom skladu i omogućavaju ispunjavanje potreba i očekivanja sadašnjih i budućih naraštaja, što je prikazano slikom 4.9. [43, 48]



Slika 4.9. Održivi razvoj [43]

Potpuno implementiran zeleni proizvodni sustav utječe na svaku funkciju poslovanja poput: marketinga, računovodstva, ljudskih resursa, dobavljača, kupaca, proizvodnje i dr. Međutim, rijetke su tvrtke koje su preuzele zeleni sustav do tih granica. Većina proizvođača počinje s implementacijom zelenog sustava u procesu proizvodnje iz koje dalje, tijekom vremena, proširuju zeleni sustav. Za razumijevanje definicije zelenog proizvodnog sustava potrebno je razumjeti njegov cilj, a to je smanjenje štetnog utjecaja na okoliš. [48]

4.8.1. Vrste gubitaka zelene proizvodnje

Kao i u slučaju vitke proizvodnje, zelena proizvodnja također se fokusira na sedam vrsta gubitaka prisutnih u tradicionalnim poslovnim sustavima:

- 1.) *Gubici energije* – nastaju u procesu proizvodnje proizvoda ili usluge primjenom više energije nego što je potrebno. Gubitak se može sagledati i kao nekorištenje obnovljivih izvora energije (sunce, vjetar i sl.).
- 2.) *Voda* – često se upotrebljava u proizvodnim procesima kao rashladni medij ili kao sastavni dio proizvodnog procesa. Upotreba većih količina vode od onoga što je potrebno uzrokuje povećane troškove i povećava cijenu proizvoda. Pročišćavanjem vode i ponovnim vraćanjem pročišćene vode u proizvodni proces smanjuju se troškovi.
- 3.) *Gubici materijala* – kao posljedica primjene neadekvatnih materijala i sirovina u proizvodnim procesima. Reduciraju se primjenom materijala koji se mogu reciklirati i zamjenom opasnih materijala i sirovina bezopasnim.
- 4.) *Gubici zbog otpada* – nastaju zbog skupog pakiranja proizvoda, dodatne ambalaže i sličnih dodataka proizvodu koji se jednokratno koriste i zatim bacaju.
- 5.) *Gubici zbog transporta* – nastaju zbog nepotrebnih kretanja ljudi, materijala, sirovina, proizvoda i informacija.
- 6.) *Emisije štetnih plinova* – nastaju kao rezultat plaćanja naknada za ispuštanje štetnih plinova u okoliš i atmosferu.
- 7.) *Bioraznolikost* – prevelikim iskorištavanjem prirodnih resursa narušava se ravnoteža cjelokupnog ekosustava, a to uzrokuje direktno uništavanje flore, faune i živih organizama.

Vitki proizvođači nadilaze tradicionalne granice vitke proizvodnje i provode zelenu proizvodnu strategiju kao dio svoje ukupne strategije smanjenja otpada. Time postižu izvrsne rezultate i na području vitke i zelene proizvodnje, osobito na smanjenju troškova, što ukazuje na sinergiju između vitkih i zelenih proizvodnih sustava [48]. Tablicom 4.6 prikazan je ekološki utjecaj na tipične vrste gubitaka prema vitkoj proizvodnji.

Tablica 4.6. Ekološki utjecaj na tipove rasipanja u proizvodnji [45]

Vrsta gubitka	Ekološki utjecaj
Prekomjerna proizvodnja	<ul style="list-style-type: none"> • Veća potrošnja sirovina i energije za stvaranje nepotrebnih proizvoda. • Višak proizvoda može se pokvariti ili zastarjeti, što zahtijeva odlaganje. • Dodatna upotreba opasnih materijala rezultira dodatnim emisijama, dodatnim zbrinjavanjem otpada i dodatnim rizikom kojemu su izloženi radnici.
Transport i nepotrebna kretanja	<ul style="list-style-type: none"> • Više se energije koristi za transport => više emisija uslijed transporta. • Više ambalaže potrebno za zaštitu proizvodnih komponenti tijekom transporta. • Oštećenja i izlivanje tijekom transporta. • Transport opasnih tvari zahtijeva poseban prijevoz i ambalažu kako bi se spriječio rizik od nesreća.
Čekanje	<ul style="list-style-type: none"> • Gubici uslijed potencijalnog kvarenja materijala ili oštećenja dijelova. • Gubitak energije potrošene na grijanje, hlađenje i rasvjetu tijekom proizvodnog zastoja.
Prekomjerna obrada	<ul style="list-style-type: none"> • Više dijelova i sirovina konzumiranih po jedinici proizvodnje. • Nepotrebna obrada povećava emisije, potrošnju energije i količinu otpadnog materijala.
Prekomjerne zalihe	<ul style="list-style-type: none"> • Više ambalaže za pohranjivanje materijala između operacija. • Gubici uslijed pohranjivanja materijala zbog propadanja ili oštećenja. • Više je materijala potrebno za zamjenu zbog oštećenja. • Više se energije koristi za grijanje, hlađenje i osvjetljenje skladišnog prostora.
Greške (škart)	<ul style="list-style-type: none"> • Sirovine i energija potrošena u izradi neispravnih proizvoda. • Neispravni proizvodi zahtijevaju zbrinjavanje ili reciklažu. • Više prostora potrebnog za popravak ili preradbu znači povećanje energije za grijanje, hlađenje i rasvjetu.
Nedovoljno korištenje potencijala radnika	<ul style="list-style-type: none"> • Ne koristi se znanje radnika na projektima vezanima uz ekologiju. • Ne primjenjuju se alati kao što su Kaizen radionice za unaprjeđenje procesa.

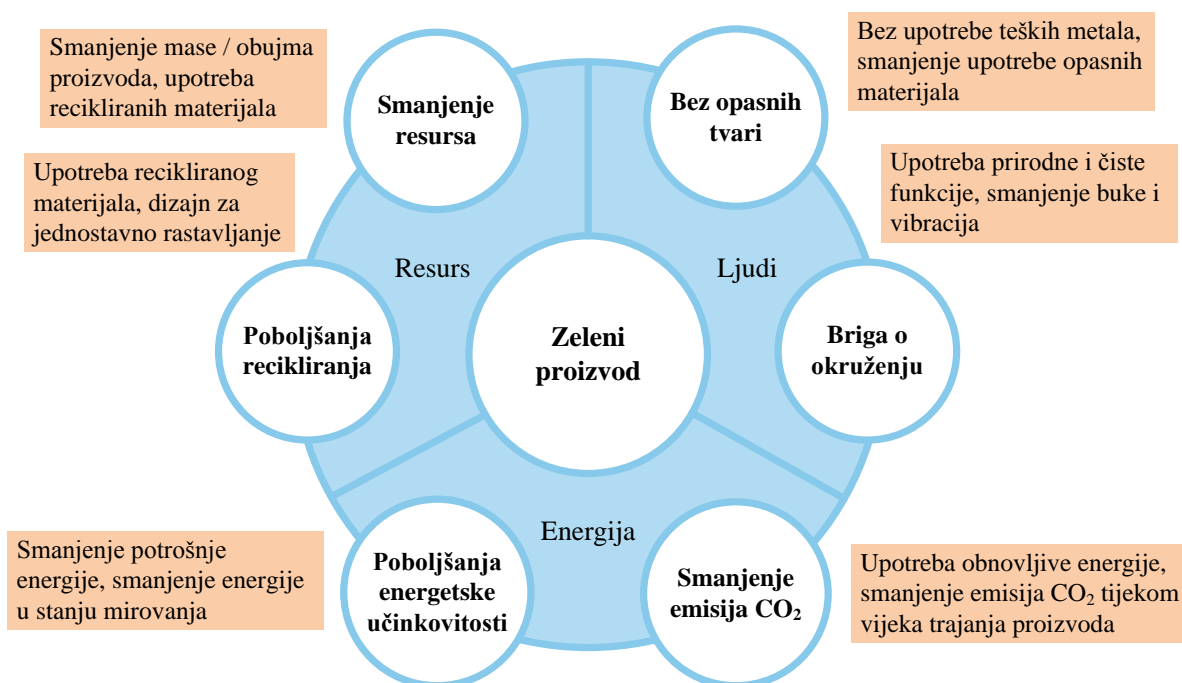
4.8.2. Implementacija zelene proizvodnje

Smanjenjem štetnog utjecaja na okoliš smanjuju se troškovi materijala i energije te rizici poslovanja poduzeća vezani uz zakonske propise. Obavezom smanjenja štetnog utjecaja na okoliš, alati i tehnike vitke proizvodnje koji se primjenjuju za smanjenje proizvodnih gubitaka srž su zelene proizvodne strategije. Integrirani vitki i zeleni model proizvodnih sustava predlaže se kao rješenje za ekonomski i ekološki održivu proizvodnju. [48]

Glavna su načela zelene proizvodne strategije: [45]

- smanjenje emisije štetnih tvari
- smanjenje proizvodnih gubitaka i otpada
- zamjena opasnih tvari i materijala
- zatvaranje kružnog toka materijala
- očuvanje prirodnih resursa
- učinkovitije korištenje postojećih i traženje novih izvora energije
- razvoj i uvođenje čistijih tehnologija.

Aktivnosti smanjivanja utjecaja na okoliš potrebno je uzeti u obzir tijekom razvoja proizvoda te ih provoditi tijekom proizvodnje i upotrebe proizvoda (slika 4.10) [43].



Slika 4.10. LG ekološki dizajn [43]

Poticaji za upravljanje poduzećem putem zelene proizvodne strategije: [43, 48]

- smanjenje izloženosti zakonskim propisima i kaznenim prijavama
- "zelena" proizvodna rješenja poboljšavaju učinkovitost resursa, smanjenje troškova, materijala, energije, vode, gospodarenja otpadom i zbrinjavanje
- kontinuirani rast poduzeća kroz usvajanje novih znanja i tehnologija
- poduzeća koja djeluju u globalnoj ekonomiji imaju koristi od globalnog prihvatanja ekološki savjesnog ponašanja, čime se smanjuje trgovinska barijera
- potražnja za ekološki osviještenim proizvodima u porastu je
- korištenje sredstava iz fondova Europske unije za zelenu i vitku proizvodnju (do 2020. godine 105 mlrd eura)
- uspostavljanje odnosa između dobavljača i kupaca kroz praćenje proizvoda tijekom cijelog životnog ciklusa.

5. DOSADAŠNJE SPOZNAJE NA PODRUČJU UČINKOVITOGA UPRAVLJANJA PROIZVODNjom / PODUZEĆEM

Kontinuirano smanjenje troškova, povećanje kvalitete i smanjenje vremena isporuke potiče poduzeća na stalno poboljšavanje poslovnih procesa, a to je i veliki izazov u upravljanju poslovanjem u visoko konkurentnim tržištima. Stoga se ulaže puno napora kako bi postala vitka poduzeća. Prodajne cijene uglavnom diktiraju tržište, pa je jedina mogućnost za povećanje dobiti smanjenje troškova. Uz smanjenje troškova potrebno je kontinuirano raditi na povećanju kvalitete i smanjenju vremena proizvodnje ili pružanja usluga [2, 11].

Tijekom 80-ih i 90-ih godina prošlog stoljeća razvijen je veći broj tehnika i alata učinkovitoga upravljanja proizvodnjom (poduzećima) među kojima je i vitka proizvodnja. Posljednjih 10 do 15 godina, uz važnost povećanja učinkovitosti poduzeća, pridodaje se sve veća važnost utjecaju proizvoda i usluga na okoliš. Od poduzeća se zahtijeva da proizvode cjenovno i ekološki prihvatljive proizvode ili usluge. Za razliku od ranijih godina kada su ekološki zeleni proizvodi i usluge bili luksuz, danas je nužno usvajanje "zelene" prakse tijekom cijelog opskrbnog lanca ako se želi zadržati tržišni udio bez povećanja ukupnih troškova [5, 49].

U nastavku rada obrađena su istraživanja vezana uz učinkovito upravljanje proizvodnjom (poduzećem) temeljena na navedenim suvremenim tehnikama i alatima upravljanja, odnosno vitkoj i zelenoj proizvodnji. Također su obrađena i istraživanja vezana uz metode odlučivanja, točnije primjenu analitičkog hijerarhijskog procesa (e. *Analytic Hierarchy Process - AHP*), odnosno višekriterijskog odlučivanja za donošenje odluka u složenim uvjetima poput implementacije vitke metodologije u poduzeće.

5.1. Spoznaje vezane uz primjenu tehnika i alata vitke i zelene proizvodnje

Vitka proizvodnja metoda je organizacije i upravljanja razvojem proizvoda, poslovanjem, dobavljačima i odnosima s klijentima [37], a ona je detaljno obrađena u poglavlju 4.7. U nastavku se navode dosadašnje spoznaje vezane uz analizu, primjenu, probleme i rezultate implementacije vitke proizvodnje.

Razjašnjavanjem pojma vitke proizvodnje i njenog razvoja došlo se do zaključka da vitka proizvodnja nije jednoznačan pojam, poput kontinuiranog poboljšanja, proizvodnje u pravo vrijeme, potpunog upravljanja kvalitetom itd., nego je pojmovno višeznačna, a njezina definicija odnosa između ovih temeljnih komponenti obuhvaća filozofske značajke koje je teško izravno mjeriti [50]. Često se za vitku proizvodnju primjenjuju pojmovi kao npr. vitka proizvodnja poslovni je sustav, vitka proizvodnja je metodologija proizvodnih sustava ili vitka proizvodnja implementira metodologije i alate itd., čime se zaključuje da i u literaturi i u praksi sam pojam vitke proizvodnje nije razjašnjen [6, 7, 37, 50].

Analizom primjenljivosti metoda vitke proizvodnje u procesnoj proizvodnji (u industriji čelika u SAD-u) zaključeno je da su metode vitke proizvodnje: 5S, mapiranje toka vrijednosti (e. *VSM*) i andon (vizualni sustav) u potpunosti primjenljivi dok su metode poput: proizvodnja u pravo vrijeme (e. *JIT*), niveliranje proizvodnje (e. *Production leveling*) te cjelovito produktivno održavanje (e. *TPM*) djelomično primjenjivi u slučaju procesne proizvodnje. [51]

Istraživanjem razvoja pristupa koji podupire unaprjeđenje upravljanja informacijama i cjelokupne informacijske infrastrukture utvrđeno je da se je za postizanje vitkog upravljanja informacijama potrebno fokusirati na pet načela vitkog načina razmišljanja: vrijednosti, vrijednosti tokova, protoka, povlačenja i kontinuiranog unaprjeđenja s gledišta upravljanja informacijama [52, 53].

U 2005. godini stopa povrata robe od strane kupca u SAD-u iznosila je oko 15 % [54] dok je u slučaju kataloške prodaje i internet prodaje iznosila čak 35 % [54]. Analizom modela proizvodnog menadžmenta koji razmatra mogućnost uvođenja povratne logistike (e. *reverse-logistics*) i sustava za daljnju obradu (recikliranje i sl.) proizvoda "na kraju životnog vijeka proizvoda" (e. *end-of-life products*) dobiveni su rezultati koji pokazuju da se mogu ostvariti ekonomske prednosti koje pomažu poduzećima da povećaju svoju konkurentnost. Navedeno se ostvaruje preradom u skladu s načelima vitke proizvodnje te uz provedbu mješovite strategije koja objedinjuje proizvodnju, djelomično recikliranje, zbrinjavanje i preradu. [54, 55]

Mnogi autori preporučuju implementaciju vitke proizvodnje u proizvodni sustav jer zahtijeva manje ljudskog napora, manje prostora, manje kapitala, manje materijala, skraćuje vrijeme izrade proizvoda, povećava kvalitetu proizvoda, čime se postiže bolja ukupna financijska i

operativna kontrola [37, 12, 56]. Kod provedbe vitke proizvodnje potrebno je vrlo pažljivo analizirati zaposlenike, tehnologiju i organizacijske karakteristike i njihove interakcije, a to zahtijeva sustavan pristup, koji je dovoljno sveobuhvatan za pokrivanje svih parametara sustava [12].

Unatoč prednostima koje donosi vitka proizvodnja, njezina potpuna implementacija nije nimalo jednostavna. Istraživanje provedeno 2007. godine u Sjedinjenim Američkim Državama pokazalo je da se u gotovo 70 % poduzeća primjenjuje vitka metodologija kao metodologija poboljšanja. Međutim samo 2 % poduzeća izjavilo je da su u potpunosti ostvarila svoje ciljeve implementacijom vitke metodologije. Manje od četvrtine poduzeća (24 %) izjavilo je da su postigli znatne rezultate implementacijom vitke metodologije [57].

Zelena proizvodnja objašnjena je u poglavlju 4.8. U nastavku se navode dosadašnje spoznaje vezane uz primjenu, probleme i rezultate implementacije zelene proizvodnje.

Često se misli da zelena proizvodnja jednostavno znači kontrolu onečišćenja ili uvođenje sustava recikliranja u proizvodni sustav, međutim ona predstavlja mnogo širi pojam koji se temelji na ciljevima poput smanjenja emisija i ekoloških katastrofa (nesreća), smanjenje upotrebe sirovina i obnovljivih oblika energije, te smanjenje utjecaja održavanja i servisiranja proizvoda tijekom životnog vijeka [58].

Često puta gospodarski rast ignorira utjecaj na okoliš. Čista proizvodnja (e. *Cleaner Production*) može smanjiti troškove na temelju konkurentne prednosti i smanjenog utjecaja na okoliš [59]. Temelj je koncepta čiste proizvodnje planiranje, ispitivanje, ponovno ocjenjivanje i održavanje proizvodnog procesa kojim se ostvaruje veća produktivnost, uz manji utjecaj na okoliš.

Većina literature vezana uz zelenu proizvodnju bavi se otpadom (e. *waste*) koji predstavlja velik izvor onečišćenja okoliša, ne samo tla i podzemnih voda, nego i zraka. Otpad također predstavlja velik izvor energije koji se ne smije samo tako odbaciti [60]. Jedan dio komunalnog otpada može se reciklirati dok se drugi može primijeniti kao gorivo. Recikliranjem i uporabom plastične [61] i staklene ambalaže [62], ostvaruju se velike uštede energenata i sirovina [63] te se znatno smanjuje utjecaj na okoliš [64, 65].

5. Dosadašnje spoznaje na području učinkovitoga upravljanja proizvodnjom / poduzećem

Čista proizvodnja znači primjenu onih sirovina i proizvoda u industrijskim procesima koji su već u fazi projektiranja konstruirani tako da se smanji onečišćenje zraka, vode i zemlje, radi smanjenja otpada, kako bi se smanjio utjecaj na okoliš i zdravlje ljudi, te kako bi se ostvarila učinkovitija primjena sirovina, energije, vode i prostora [66, 67].

Prethodno navedeni primjeri uglavnom se odnose na područja primjene tehnika i alata vitke i zelene proizvodnje. Vidi se da njihova primjenljivost nije samo u proizvodnim djelatnostima, nego gotovo u svim djelatnostima, pa i u uslužnima. Također se zaključuje da ne postoji granica koja odjeljuje vitku i zelenu proizvodnju, nego se naprotiv jedna i druga gotovo isprepleću na svim područjima.

Kao što je naglašeno, cilj je rada izrada modela učinkovitoga upravljanja koji se može uspješno primijeniti i u proizvodnim i u uslužnim poduzećima. Budući da su spoznaje o primjeni suvremenih tehnika i alata vitke i zelene proizvodnje u hrvatskim poduzećima prikupljana putem ankete, u nastavku se navodi nekoliko istraživanja drugih autora koji su svoje zaključke također donijeli na temelju provedenih anketa ili intervjua. Rezultati ovih provedenih istraživanja drugih autora detaljnije su prikazani u poglavlju 6.3.2., gdje su korišteni za usporedbu s obrađenim podacima prikupljenima putem ankete u Republici Hrvatskoj (RH).

Istraživanjem vezanim uz definiranje ključnih faktora za uspješnu implementaciju vitkog menadžmenta u automobilske industriji, koje je provedeno putem ankete, na poduzećima koja su provela organizacijske promjene i filozofiju Toyotina proizvodnog sustava (TPS), došlo se do sljedećih spoznaja. Vitki način upravljanja nije jednostavan skup alata i tehnika koji se može provesti zapovijedanjem i nadzorom, nego je u potpunosti integrirano upravljanje, proizvodna filozofija i pristup u kojem je ljudski faktor najvažniji element uspjeha. Zaključuje se da kultura (mentalitet, osobni ciljevi i sl.) i rukovodstvo imaju puno važniju ulogu u postizanju učinkovitijeg poduzeća od samih TPS alata. Vrlo često se poduzeća usredotočuju na čisto smanjenje troškova, misleći da će jednostavnim kopiranjem TPS alata postići cilj. TPS alati su važni i sredstvo su za postizanje cilja, ali za postizanje vitkog upravljanja potrebne su promjene u filozofiji, upravljačkom sustavu i pristupu. [11]

Istraživanjem s pomoću intervjua financijskih institucija u Južnoj Africi koje su primijenile vitki pristup, usredotočilo se na definiranje čimbenika koji doprinose učinkovitoj provedbi

vitkog menadžmenta pa se došlo do zaključka da postoji pet glavnih čimbenika za uspješnu provedbu vitkih projekata:

- predanost i angažman višeg menadžmenta
- aktivna uključenost zaposlenika u projekt
- osigurana sredstva i zaposlenici s relevantnim i odgovarajućim vještinama te kompetencijama za izvršenje promjena
- kultura usmjerena na vitki način razmišljanja, a na kraju
- da sve uključene strane imaju jasan zajednički cilj i razumijevanje onoga što je cilj projekta. [68]

Dijelom do gotovo istih, prethodno navedenih, zaključaka došlo je i mnogo drugih autora. Npr. Kennedy, A.G. u radu [10] proveo je istraživanje u poduzeću za proizvodnju mikroelektroničkih dijelova u gradu Twin Cities, Minnesota, USA. Istraživanje je provedeno putem ankete, intervjua i sociograma te metode mjerenja i praćenja razvoja kulture kontinuiranog poboljšanja na zaposlenicima montažne proizvodne linije, prilikom prijelaza iz masovne proizvodnje u vitku proizvodnju.

Istraživanje s pomoću ankete i intervjua o tome kako malo poduzeće može implementirati vitku filozofiju u vlastitu organizaciju proveli su Housmand, M. i Jamshidnezhad, B. [12] na četiri poduzeća srednje veličine u Švedskoj. Navedena poduzeća bave se različitim djelatnostima: proizvodnja strojeva za pakiranje proizvoda široke potrošnje, proizvodnja ventilacijskih kanala, razvoj i proizvodnja hidrauličnih pumpi te proizvodnja strojeva za pakiranje za farmaceutsku industriju [12].

5.2. Spoznaje vezane uz primjenu metoda višekriterijskih analiza

Kako bi se unaprijedilo donošenje odluka u složenim uvjetima, važno je razvijati i primjenjivati nove alate kojima se ujedno podiže razina transparentnosti i objektivnosti izbora rješenja. Za pomoć pri odabiru rješenja primjenjuju se i razvijaju metode višekriterijske analize. Višekriterijska analiza primjenljiva je kod odabira između više generiranih rješenja temeljem većeg broja kriterija i različitih, kvantitativnih i kvalitativnih mjera. [69]

Deluka-Tibijaš, A., Karleuša, B., Dragičević, N. u radu [69] provele su analizu primjena metoda višekriterijske analize pri odabiru rješenja u planiranju, projektiranju, izvedbi, održavanju i rekonstrukciji prometne infrastrukture u urbanim područjima. Analiza pokazuje da se metoda višekriterijske analize u procesu rješavanja problema pretežno primjenjuje u fazi planiranja prometne infrastrukture u urbanim područjima, a znatno manje u fazi projektiranja ili održavanja i rekonstrukciji. Provedenom analizom primjene metoda pokazalo se da se u procesu donošenja odluka o prometnoj infrastrukturi najčešće primjenjuje metoda AHP (e. *Analitic Hierarchy Process*). Nakon nje po zastupljenosti se ističe PROMETHEE (e. *Preference Ranking Organization METHod for Enrichment Evaluations*), a zatim ELECTRE (e. *ELiminationand (Et) Choice Translating REality*) i metoda jednostavnih aditivnih težina. Rjeđe se primjenjuju ANP (e. *Analytic Network Process*), metoda višeatributivne teorije korisnosti/vrijednosti, TOPSIS (e. *Technique for Order Preference by Similarityto Ideal Solution*) i ostale metode. Autori zaključuju da je AHP metoda rasprostranjena pri donošenju odluka vezanih uz prometnu infrastrukturu radi jednostavnosti i fleksibilnosti u primjeni jer omogućava provedbu analize i odabira rješenja temeljem usporedbe parova varijanti u odnosu na kriterije i temeljem kriterija u odnosu na cilj. Također zaključuju da metode višekriterijske analize doprinose kvaliteti provedbe postupka donošenja odluka o prometnoj infrastrukturi u urbanim područjima osiguravanjem objektivnosti, transparentnosti i mogućnosti provedbe kontrole samog postupka donošenja odluka.

Istraživanjem vezanim uz primjenu AHP metode u procesu projektiranja skladišta došlo se do sljedećih spoznaja. Kao glavni problemi u procesu projektiranja skladišta navode se: odabir najboljeg rješenja skladištenja, odabir opreme za rukovanje, izgled skladišta, operativne politike, ciljane performanse (troškovi, prostor, kapacitet pohrane, i dr.). Zbog velikog broja mogućih rješenja, često je potrebno postići kompromis između suprotstavljenih ciljeva te je teško odabrati najbolje rješenje na osnovi samo jednog kriterija. Upotrebom AHP višekriterijskog načina odlučivanja, zbog višestrukih kriterija, znatno se olakšava donošenje odluke. Usporedba u parovima, kombinacijom kvalitativnih i kvantitativnih podataka (kriterija) čini AHP metodu vrlo popularnom za primjenu u raznim područjima, pa tako i kod projektiranja skladišnih prostora. [70]

5.2.1. Primjena AHP metode kod implementacije vitkih alata

Za odabir najprikladnijeg rješenja s gledišta troška i vremena implementacije vitkih alata u zdravstvene ustanove u Iranu primijenjena je AHP metoda. Trošak i vrijeme implementacije uzeti su u obzir kod izračuna matrica s težinskim faktorom od 0,3 za cijenu i 0,7 za vrijeme implementacije vitkih alata. Razmatrana su tri načina implementacije vitkih alata u zdravstvene ustanove (alternative): vanjski konzultanti, studenti (putem studentskih projekata) i zaposlenici zdravstvenih ustanova. Kao osnovni kriteriji, upotrijebljeno je pet vitkih alata: gubici (sedam vrsta gubitaka prema vitkoj metodologiji), Kanban, Kaizen, 5 S i Poka Yoke. Provedenim istraživanjem došlo se do zaključka da su vanjski konzultanti najprikladnije rješenje za implementaciju vitkih alata u zdravstvene ustanove u Iranu. Autori također preporučuju primjenu AHP metode za istraživanja kod provedbe vitke metodologije i u drugim područjima (industrijama). [71]

Analizom čimbenika koji utječu na implementaciju vitke metodologije u mikro, mala i srednje velika poduzeća u Indiji došlo se do sljedećih spoznaja. Od gotovo 30 znatnih čimbenika koji su dobiveni proučavanjem literature i od stručnjaka iz područja industrije i znanosti odabrano je 11 najistaknutijih čimbenika. Ovih 11 čimbenika analizirano je primjenom strukturalnog modeliranja (e. *Structural Equation Modeling – SEM*) i analitičkog hijerarhijskog odlučivanja tako da su dobiveni sljedeći podaci. Analizirani faktori uspjeha klasificirani navedenim metodama od najutjecajnijih prema manje utjecajnim jesu: financijske mogućnosti tvrtke, podrška vrhovnog menadžmenta, spremnost organizacije na promjene u organizaciji i kulturi, poboljšanje poslovne strategije i dr. [72]

6. ISTRAŽIVANJE O UPRAVLJANJU PODUZEĆIMA U RH

Kako bi se dobila slika o broju poduzeća, o broju zaposlenih osoba i sl. aktivnih na području RH, te da se vide trendovi kretanja proteklih godina, upotrijebljeni su strukturno-poslovni pokazatelji poduzeća u RH. Navedeni pokazatelji korišteni su za usporedbu s rezultatima istraživanja provedenog putem ankete o učinkovitom upravljanju poduzećima u RH.

Većina poduzeća u svijetu svoj razvoj i unapređenje temelje na primjeru Toyotinog proizvodnog sustava (*e. Toyota production system - TPS*) te na vitkoj proizvodnji (*e. Lean production - LP*) i zelenoj proizvodnji (*e. Green production - GP*). Informacije o tome da li se navedeni alati i tehnike učinkovitoga upravljanja primjenjuju, i u kojoj mjeri, u hrvatskim poduzećima prikupljene su putem ankete.

Prikupljeni podaci statistički su obrađeni i uspoređeni s podacima dobivenim anketama drugih autora. Sadržaj ankete, način prikupljanja podataka i rezultati statističke obrade prikupljenih podataka navode se u onom što slijedi.

6.1. Strukturno-poslovni pokazatelji poduzeća u RH

Državni zavod za statistiku RH u svom priopćenju "Strukturno-poslovni pokazatelji poduzeća" objavljuje konačne godišnje strukturno-poslovne pokazatelje za "nefinancijsko poslovno gospodarstvo" Republike Hrvatske. Riječ je o djelatnostima industrije, građevinarstva, trgovine i nefinancijskih usluga, odnosno djelatnostima koje u najvećem dijelu čine tzv. realni sektor. Predmetni podaci u potpunosti su u skladu s europskim normama strukturnih poslovnih statistika (Uredba br. 295/2008 Europskog parlamenta i Vijeća od 11. ožujka 2008.) i međunarodno su usporedivi.

Iz predmetnih priopćenja (za razdoblje od 2008. do 2013.) upotrijebljeni su podaci o strukturno-poslovnim pokazateljima poduzeća (poput: broj poduzeća, broj zaposlenih osoba, ukupan promet, struktura poduzeća po veličini poduzeća i sl.) koji su preuzeti iz službenih priopćenja *Državnog zavoda za statistiku (DZS)* [73]. Navedeni odabrani podaci navode se u onom što slijedi.

Tablica 6.1. Broj i udjeli poduzeća prema veličini poduzeća u razdoblju od 2008. do 2012. [73]

godina	ukupan promet, (mlrd. kuna)	broj poduzeća	Broj i udjeli poduzeća prema veličini poduzeća									
			srednja i mala poduzeća (SMP)								velika (250 +)	
			ukupno (mikro, mala, srednja)		mikro (<10)		mala (10 - 49)		srednja (50 - 249)			
			broj poduzeća	%	broj poduz.	%	broj poduz.	%	broj poduz.	%		
2008.	692,8	167.292	166.789	99,7	152.240	91,0	12.384	7,4	2.174	1,3	494	0,3
2009.	600,2	180.430	179.973	99,7	165.904	91,9	12.005	6,7	2.064	1,1	457	0,3
2010.	568,9	165.490	164.994	99,7	152.251	92,0	10.922	6,6	1.986	1,2	496	0,3
2011.	575,9	153.687	153.226	99,7	140.931	91,7	10.451	6,8	1.844	1,2	461	0,3
2012.	565,9	148.573	148.127	99,7	136.092	91,6	10.252	6,9	1.783	1,2	446	0,3

U tablici 6.1 zelenom bojom grafički je prikazano kretanje ukupnog prometa, plavom bojom broj poduzeća u razdoblju od 2008. do 2012. (po godinama), dok su crvenom bojom prikazani udjeli poduzeća prema veličini poduzeća po pojedinoj godini.

U tablici 6.2 zelenom bojom grafički je prikazano kretanje ukupnog prometa, plavom broj zaposlenih osoba u razdoblju od 2010. do 2012. (po godinama), dok su crvenom bojom prikazani udjeli zaposlenih osoba prema veličini poduzeća po pojedinoj godini.

Tablica 6.2. Broj i udjeli zaposlenih osoba prema veličini poduzeća u razdoblju od 2010. do 2012. [73]

godina	ukupan promet, (mlrd. kuna)	broj poduzeća	Broj i udjeli zaposlenih osoba prema veličini poduzeća										
			srednja i mala poduzeća (SMP)									velika (250 +)	
			ukupno (mikro, mala, srednja)		mikro (<10)		mala (10 - 49)		srednja (50 - 249)				
			br. zap. osoba	%	br. zap. osoba	%	br. zap. osoba	%	br. zap. osoba	%	br. zap. osoba	%	
2010.	568,9	1.075.442	743.130	69,1	334.462	31,1	206.485	19,2	202.183	18,8	332.312	30,9	
2011.	575,9	1.033.145	705.638	68,3	310.977	30,1	197.331	19,1	197.331	19,1	327.506	31,7	
2012.	565,9	1.002.905	684.984	68,3	303.880	30,3	192.558	19,2	188.546	18,8	317.921	31,7	

Napomena: Podaci o broju poduzeća analizirani su za razdoblje od 2008. do 2012., dok su podaci o broju zaposlenih osoba analizirani za razdoblje od 2010. do 2012., jer ranijih godina pojedini podaci o broju zaposlenih osoba u pojedinim veličinama poduzeća nisu objavljeni

priopćenjem "Strukturno-poslovni pokazatelji poduzeća" Državnog zavoda za statistiku radi povjerljivosti.

Metodološka objašnjenja varijabli upotrijebljenih u prezentiranju strukturno-poslovnih pokazatelja poduzeća u prethodnim tablicama jesu: [73]

- 1.) *Ukupan promet* obuhvaća obračunate prihode od prodaje proizvoda, roba i usluga trećim stranama, bez odbitog PDV-a, pri čemu su isključeni financijski, ostali i izvanredni prihodi.
- 2.) *Broj poduzeća* broj je pravnih i fizičkih osoba registriranih u *Statističkome poslovnom registru* koje su bile aktivne barem do izvještajnog razdoblja.
- 3.) *Veličina poduzeća*. Za prezentaciju informacija o veličini poduzeća upotrijebljena je podjela poduzeća prema veličini razreda zaposlenih:
 - mikropoduzeća: manje od 10 zaposlenih osoba
 - mala poduzeća: 10 – 49 zaposlenih osoba
 - srednje velika poduzeća: 50 – 249 zaposlenih osoba
 - velika poduzeća: 250 i više zaposlenih osoba.

Uobičajeno je da se pod izrazom srednja i mala poduzeća (SMP) podrazumijevaju srednje velika, mala i mikropoduzeća. Podjela poduzeća na mikropoduzeća, mala i srednje velika poduzeća pokrenuta je na preporuku *Europske komisije* 2003/361/EC objavljene u glasilu *Službeni list Europske unije* L 124, str. 36 do 20. svibnja 2003., a stupila je na snagu 1. siječnja 2005. godine. [74]

- 4.) *Broj zaposlenih osoba* jest ukupan broj osoba koje rade u poduzeću (uključujući vlasnike koji rade, suradnike koji redovito rade u jedinici, neplaćene obiteljske radnike i volontere) te osobe koje rade izvan poduzeća kojemu pripadaju, a koje ih plaća.


Na osnovi prethodne dvije tablice (6.1 i 6.2) zaključuje se da od broja aktivnih poduzeća uvjerljivo najveći dio (99,7 % - za analizirano razdoblje od 2008. do 2012.) pripada skupini SMP (srednje velika, mala i mikropoduzeća), koja zapošljavaju više od dvije trećine osoba (69,1 % – 68,3 % - za analizirano razdoblje od 2010. do 2012.).

Unutar skupine SMP po brojnosti se izdvajaju mikropoduzeća, koja čine čak 91 % - 92 % populacije cjelokupnog nefinancijskog poslovnog gospodarstva. Skupina velikih poduzeća, iako s najmanjim udjelom u broju aktivnih poduzeća (0,3 %), uvelike pridonosi zaposlenosti (30,9 % - 31,7 % - za analizirano razdoblje od 2010. do 2012.).


Radi veće preglednosti daje se zbirni tablični i grafički prikaz ukupnog prometa, broja aktivnih poduzeća i zaposlenih osoba "nefinancijskog poslovnog gospodarstva" Republike Hrvatske (tablica 6.3 i slike 6.1 i 6.2).

Tablica 6.3. Odabrani strukturno-poslovni pokazatelji nefinancijskog poslovnog gospodarstva u razdoblju od 2008. do 2012. [73]

godina	ukupan promet		broj poduzeća		broj zaposlenih osoba	
	(mlrd. kuna)	trend (%)	broj poduzeća	trend (%)	broj zaposlenih	trend (%)
2008.	692,8		167.292		1.180.108	
2009.	600,2	● -13,4	180.430	● 7,9	1.153.441	● -2,3
2010.	568,9	● -5,2	165.490	● -8,3	1.075.442	● -6,8
2011.	575,9	● 1,2	153.687	● -7,1	1.033.145	● -3,9
2012.	565,9	● -1,7	147.583	● -4,0	1.002.905	● -2,9



Slika 6.1. Odabrani strukturno-poslovni pokazatelji nefinancijskog poslovnog gospodarstva u razdoblju od 2008. do 2012. [73]



Slika 6.2. Stopa rasta odabranih strukturno-poslovnih pokazatelja nefinancijskog poslovnog gospodarstva u 2012. (u odnosu na 2008.) [73]

Analizom obrađenih podataka vidi se da u promatranom petogodišnjem vremenskom razdoblju nefinancijsko poslovno gospodarstvo bilježi pad poslovne aktivnosti u odnosu na 2008. Negativne stope ostvarili su svi odabrani pokazatelji. Najveći pad bilježi "ukupan promet" nefinancijskog poslovnog gospodarstva RH sa visokih 18,3 %, a u istom razdoblju broj zaposlenih osoba smanjen je za 15 % i zatvoreno je 11,8 % poduzeća.

Unutar navedenog petogodišnjeg razdoblja analizom na godišnjoj razini (usporedba s prethodnom godinom) jedino je u 2009. zabilježen porast broja poduzeća za 7,9 % (13.138 poduzeća) i u 2011. kada je zabilježen porast ukupnog prometa za 1,2 % (7,0 mlrd. kuna) dok je u ostalim godinama zabilježen pad svih odabranih pokazatelja (ukupnog prometa poduzeća, broja poduzeća i broj zaposlenih osoba).

Iz navedenog, je moguće zaključiti da je vrlo nepovoljan trend osnovnih strukturno-poslovnih pokazatelja poduzeća nefinancijskog poslovnog gospodarstva u RH u promatranom petogodišnjem razdoblju. Zabilježen je pad ukupnog prometa, broja zaposlenih osoba i broja poduzeća, a navedeni negativni trend ima tendenciju daljnjeg pada (slika 6.2).

6.2. Prikupljanje podataka

U nastavku su navedeni načini prikupljanja podataka od nekoliko drugih autora, u vezi s učinkovitim upravljanjem i njihovim ciljanim grupama sudionika istraživanja.

Prema literaturi [11] za istraživanje u vezi s definiranjem ključnih faktora za uspješnu implementaciju vitkog menadžmenta odabrana su poduzeća koja su provela organizacijske promjene i filozofiju Toyotina proizvodna sustava (TPS). U okviru istraživanja kontaktiran je, putem elektroničke pošte (poslana je anketa), velik broj rukovoditelja i direktora automobilske industrije, radi prikupljanja relevantnog uzorka od poduzeća koja djeluju u cijelom svijetu. Anketa je zatvorena nakon točno tri tjedna, a od 270 poslanih anketa povratno je dobiveno 65 anketa s odgovorenih najmanje 97 % svih pitanja. Budući da su većina sudionika viši menadžeri, s kojima je autor desetak godina radio na uvođenju vitkih koncepata, autor je zadovoljan odazivom sudionika istraživanja (65/270 što odgovara 24,1 %) u popunjavanju ankete.

Prema literaturi [68], istraživanje vezano uz definiranje parametara koji doprinose učinkovitoj provedbi vitkog menadžmenta unutar bankarskog sektora u Južnoj Africi provedeno je u financijskim institucijama koje su usvojile vitki pristup tako da je proveden intervju licem u lice (e. *face-to-face*) odabranih 20 osoba (direktora i rukovoditelja) koje su sudjelovale u implementaciji vitkog načina upravljanja.

Istraživanje u vezi s procjenom učinkovite primjene istraživačkih metoda u vitkom proizvodnom okruženju opisano je u literaturi [10]. Istraživanje obuhvaća anketu, intervju i sociogram te metode mjerenja i praćenja razvoja kulture kontinuiranog poboljšanja na zaposlenicima montažne proizvodne linije (trake) prilikom prijelaza iz masovne proizvodnje u vitku proizvodnju. Za sudjelovanje u istraživanju dobrovoljno se prijavilo 13 zaposlenika montažne proizvodne linije (trake), od ukupno 25 zaposlenika, poduzeća za proizvodnju mikroelektroničkih dijelova u gradu Twin Cities, Minnesota, USA.

Vidljivo je da su, ovisno o području istraživanja, pojedini autori upotrijebili različite načine prikupljanja podataka – putem anketa, intervjua licem u lice ili kombinacijom navedenih načina. Prikupljanje podataka od velikog broja poduzeća različitih lokacija (geografskog

položaja) poduzeća optimalno je provesti slanjem ankete putem elektroničke pošte, međutim na takav način anketiraja odaziv sudionika istraživanja nije velik [11].

Budući da je cilj rada dobivanje modela učinkovitoga upravljanja proizvodnim sustavima te opći model učinkovitoga upravljanja poduzećima u RH, područje istraživanja nisu samo proizvodne, nego uslužne i ostale djelatnosti poduzeća. Radi što većeg broja obuhvaćanja poduzeća u RH pristupilo se prikupljanju podataka s pomoću ankete.

6.2.1. Sadržaj ankete

Anketa je koncipirana tako da se prikupi što više informacija o upravljanju poduzećima s gledišta učinkovitoga upravljanja poduzećima – ovdje se misli na primjenu (implementaciju) nekih od alata i tehnika učinkovitoga upravljanja poduzećem. Što se tiče izgleda ankete, pazilo se na broj anketnih pitanja, kako anketa ne bi bila predugačka, a s druge strane da se prikupi dovoljna količina podataka na osnovu kojih se mogu izvesti kvalitetni zaključci.


Kako bi se obrađeni rezultati ankete mogli usporediti s rezultatima provedenih istraživanja u nekim drugim državama, pojedina anketna pitanja preuzeta su od drugih autora [11, 75]:

- Kada govorite o učinkovitom upravljanju poduzećem, mislite li na:
- Vaše poduzeće investiralo bi u povećanje učinkovitosti poslovanja radi?
- Odaberite alat koji se primjenjuje u Vašem poduzeću da bi postali učinkovitije poduzeće!
- Koja od sljedećih tvrdnji najviše utječe na uspješnost nekog poduzeća?
- Procijenite na skali od 1 do 5 sljedeće tvrdnje koje se odnose na komunikaciju kod provedbe projekta!

Kako bi se testirala prikladnost pitanja, odnosno jesu li su nejasna, dvosmislena i sl., izrađena anketa poslana je petorici ispitanika koji su dali svoje primjedbe. Njihove primjedbe prokomentirane su s psihologicom s iskustvom u izradi anketa, pa je izrađena konačna verzija ankete. Test je pokazao da je popunjavanje ankete moguće popuniti u 10 minuta, što je sasvim prihvatljivo vrijeme ispunjavanja.

Sama je anketa anonimna i sastoji se od sedam pitanja uglavnom zatvorenog tipa, jedino je na dva pitanja dodana kategorija "ostalo" kako bi ispitanici mogli dati svoje mišljenje ili pojašnjenje.

Sadržaj ankete prikazan je slikom 6.3 i sastoji se od pet grupa pitanja.



Slika 6.3. Sadržaj ankete

Objašnjenje navedenih grupa pitanja na slici 6.3 jest:

0) Opći podaci o poduzeću i intervjuiranoj osobi

Na početku ankete potrebno je navesti: djelatnost tvrtke, broj zaposlenika tvrtke, radno mjesto intervjuirane osobe i odjel/sektor u kojem intervjuirana osoba radi, kako bi se kvalitetno klasificirali prikupljeni podaci.

I) Testiranje razumijevanja vitke filozofije (anketna pitanja: 1., 2. i 3.)

Anketna pitanja (1., 2. i 3.) upotrijebljena su za prikupljanje podataka radi analize razumijevanja vitke filozofije i učinkovitoga upravljanja poduzećima.

Prvim anketnim pitanjem, s pomoću ponuđenih izjava ("timski rad i kontinuirano unaprjeđenje", "stalno smanjenje nepotrebnih zadataka" i dr.), od sudionika istraživanja želi se saznati na što ih asocira pojam učinkovito upravljanje poduzećem.

U drugom anketnom pitanju rangiranjem navedenih tvrdnji ("uključenost i podrška menadžmenta", "vještine i stručnost zaposlenika" i dr.) sudionik istraživanja navodi što prema njegovu mišljenju najviše utječe na uspješnost poduzeća.

Treće anketno pitanje vezano je uz razloge ("stalni pritisak za unaprjeđenje operacija", "povećanje profita" i dr.) zbog kojih bi sudionici istraživanja investirali u povećanje učinkovitosti poslovanja.

II) Komunikacija kod provedbe projekata (anketna pitanja: 4. i 5.)

Četvrtim anketnim pitanjem želi se saznati na koji se način (npr: preko interneta, telefonski i dr.) uspostavlja kontakt s dobavljačima i/ili kooperantima.

Peto anketno pitanje odnosi se na komunikaciju kod provedbe projekata, ne samo unutar poduzeća nego i izvan poduzeća s dobavljačima i/ili kooperantima.

III) Primjena alata i tehnika vitke metodologije (anketno pitanje: 6.)

Ponuđenim vitkim alatima poput: mapiranje procesa, 5S, KANBAN, TPM i dr. sudionik istraživanja dodjeljuje primjenu korištenja ponuđenog alata, u poduzeću u kojem radi, radi postizanja učinkovitijeg poduzeća. Time se dobiva informacija u kojoj se mjeri primjenjuju vitki alati u anketiranim poduzećima i gdje postoji potencijal da poduzeće postane još učinkovitije.

IV) Potencijali za smanjenje gubitaka u poduzeću (anketno pitanje: 7.)

Za navedenih osam vrsta gubitaka, prema vitkoj metodologiji, u poslovanju poduzeća (prekomjerna proizvodnja, zalihe, transport, čekanje, nepotrebna kretanja, škart, prekomjerna obrada i nedovoljna primjena potencijala radnika) sudionici istraživanja detektiraju potencijalna mjesta za povećanje učinkovitosti poduzeća navođenjem potencijala za smanjenje navedenih gubitaka.

6.2.2. Ciljane grupe sudionika istraživanja i način prikupljanja podataka

Kako bi se prikupili što kvalitetniji i vjerodostojniji podaci o načinu upravljanja poduzećima u RH, ciljane grupe sudionika istraživanja (anketiranih osoba) rukovodeći su kadar i vrhovni menadžment poduzeća. Cilj je bio prikupiti minimalno 250 ispunjenih anketa. Sam način prikupljanja podataka odvijao se u nekoliko koraka.

Prvo su preko elektroničke pošte pozvani sudionici da sudjeluju u istraživanju (anketa je poslana kao word dokument, pdf dokument i *on-line* anketa izrađena u *google docs-u*). Od ukupno oko 130 poslanih anketa osobama s kojima je ostvarena prijašnja suradnja povratno je dobiveno oko 99 anketa. Anketa je poslana i na oko 250 adresa elektroničke pošte osobama s kojima nije ostvarena prijašnja suradnja, pa je povratno dobiveno 9 anketa.

Prethodnim načinom prikupljeno je svega 108 anketa, pa je poduzet drugi korak prikupljanja podataka preko prijatelja i poznanika kojim je prikupljeno dodatnih 67 anketa. Budući da nije postignut ciljani broj ispunjenih anketa (prikupljeno 175 od ciljanih 250), pristupilo se trećem koraku prikupljanja podataka.


Treći korak prikupljanja podataka proveden je tako da se anketa u tiskanom obliku dostavila izravno (na ruke) sudionicima koji su zamoljeni da sudjeluju u istraživanju. Na ovaj način prikupljena je 121 anketa, uz najveći odaziv od oko 90 %. Uz 175 prethodno prikupljenih anketa, ukupno je prikupljeno 296 anketa, a to je iznad ciljanog broja prikupljenih anketa.

Prikupljanje podataka kroz sva tri navedena koraka, zbog slabog odaziva sudionika, trajalo je oko tri mjeseca. Broj prikupljenih anketa prikazan je u tablici 6.4 i na slici 6.4.

Tablica 6.4. Broj prikupljenih anketa

Način prikupljanja podataka	Anketa		
	poslano	dobiveno	odaziv, %
elektronički			
- bliski suradnici	130	99	76,2
- kontakti <i>Zavoda</i>	250	9	3,6
- od prijatelja, od poznanika	90	67	74,4
ukupno elektronički	470	175	37,2
papirnatu, tiskana anketa	135	121	89,6

Analizom podataka iz tablice 6.4 vidi se da je najveći odaziv (89,6 %) postignut onda kada je anketa dostavljena u papirnatom obliku sudionicima istraživanja, dok je najmanji odaziv (3,6 %) bio prikupljanjem podataka elektroničkim putem od sudionika istraživanja s kojima nije ostvarena prethodna suradnja. Vrlo dobar odaziv (76,2 %) sudjelovanja u istraživanju bio je od bliskih suradnika.

**Slika 6.4.** Broj i udio ukupno prikupljenih anketa ovisno o načinu prikupljanja podataka

Slikom 6.4 i zelenom bojom u tablici 6.4 prikazan je udio ukupno prikupljenih anketa ovisno o načinu prikupljanja i o sudionicima istraživanja. Iz analize prikupljenih anketa vidi se da je odaziv sudionika na istraživanje putem ankete, s kojima niste ostvarili prethodnu suradnju, vrlo mali (9/250 - svega 3,6 %, te čini samo 3 % ukupnog broja prikupljenih anketa), što govori da rukovodstvo hrvatskih poduzeća nije sklono sudjelovati u znanstvenim istraživanjima pa čak i ako je istraživanje vezano uz učinkovito upravljanje njihovim poduzećem.

6.3. Analiza prikupljenih podataka

Kao što je navedeno, prikupljeno je 296 anketa. Na 16 anketa nisu dani odgovori na više pitanja, pa one nisu primijenjene u daljnjoj analizi, tako da je ukupan broj anketa primijenjenih u daljnjim analizama 280.

Na gotovo sve, od 16 navedenih anketa sudionici ispitivanja nisu dali odgovor na anketno pitanje broj 6 i anketno pitanje broj 7, odnosno na:


6. Odaberite alat koji se primjenjuje u Vašem poduzeću da biste postali učinkovitije poduzeće.

7. Prema LEAN metodologiji postoji 7+1 vrsta gubitaka u poslovanju poduzeća. Na svakom pitanju (1 – 8) odaberite jedan ili više ponuđenih gubitaka (a, b, c ili d) koji se pojavljuju u Vašem poduzeću te odgovorite koliki je potencijal za smanjenje tog gubitka u Vašem poduzeću.

Tablica 6.5. Ispunjenost prikupljenih anketa

Način prikupljanja podataka	Anketa			
	prikupljeno	nepotpuno ispunjena	ispunjena	ispunjena, %
elektronički				
- bliski suradnici	99	4	95	96,0
- kontakti <i>Zavoda</i>	9	0	9	100,0
- od prijatelja, od poznanika	67	7	60	89,6
papirnat, tiskana anketa	121	5	116	95,9
Ukupno	296	16	280	94,6

Na sva pitanja ankete odgovorili su sudionici istraživanja s kojima nije ostvarena prethodna suradnja, budući da su popunjavali anketu *on-line* preko *google-docsa*, u kojem je traženo da se sva polja popune. Međutim, upravo je njihov odaziv na sudjelovanje u istraživanju najmanji 9/280, što čini svega 3,2 % (slika 6.5) od prikupljenih ispunjenih anketa. Postotak prihvatljivo ispunjenih prikupljenih anketa za ostale načine prikupljanja podataka kreće se od 89,6 % do 96,0 % i prikazan je u tablici 6.5. Slika 6.5 prikazuje analizu ispunjenosti ankete bez 16 nepotpuno ispunjenih anketa.



Slika 6.5. Broj i udio ispunjenih anketa ovisno o načinu prikupljanja podataka

6.3.1. Opće informacije o ispitanicima

Na osnovu općih podataka o poduzeću i intervjuiranoj osobi na početku ankete klasificirani su podaci prema: veličini poduzeća, djelatnosti poduzeća i sudionicima istraživanja.

Za klasifikaciju prikupljenih podataka prema veličini poduzeća korišten je podatak o broju zaposlenih osoba. Za prezentaciju informacija o djelatnostima poduzeća korištena je klasifikacija poduzeća prema *Nacionalnoj klasifikaciji djelatnosti* (NKD) [73], prema kojoj su podaci prikupljeni anketom klasificirani u četiri grupe: industrija, građevinarstvo, trgovina i nefinancijske usluge. Prikupljeni podaci klasificirani su u četiri grupe također prema sudionicima istraživanja: vrhovni menadžment, srednji menadžment, prva razina menadžmenta i operativna razina. Navedene klasifikacije prikupljenih podataka navode se u nastavku.

6.3.1.1. Klasifikacija prema veličini poduzeća

Osnovni kriteriji na temelju kojih se klasificiraju poduzeća prema veličini su [73, 74, 75]:


- *broj zaposlenih osoba* jest ukupan broj osoba koje rade u poduzeću te osobe koje rade izvan poduzeća kojem pripadaju, a koje ih plaća

- *ukupni godišnji promet* odnosi se na prihode poduzeća tijekom godine ostvaren prodajom proizvoda i usluga
- *zbroj bilance* označava ukupnu aktivu poduzeća.

Od ukupno ispunjenih 280 anketa njih 176 odnosi se na različita poduzeća na osnovu kojih je izrađena podjela prema veličini poduzeća.

Za prezentaciju informacija o veličini poduzeća upotrijebljena je podjela poduzeća samo prema broju zaposlenih osoba, kao i u literaturi [73]:

- mikropoduzeća: manje od 10 zaposlenih
- mala poduzeća: 10 – 49 zaposlenih
- srednje velika poduzeća: 50 – 249 zaposlenih
- velika poduzeća: 250 i više zaposlenih.



Slika 6.6. Broj i udjeli poduzeća prema veličini poduzeća

Slikom 6.6 prikazana je klasifikacija prikupljenih anketa prema veličini poduzeća. Najveći udio imaju mikropoduzeća od 35,2 %, najmanji je udio velikih poduzeća od 13,1 % dok su mala i srednja poduzeća s udjelima od 27,3 % i 24,4 % u ukupnom broju anketiranih poduzeća.

Radi usporedbe podataka prikupljenih anketom i podataka *Državnog zavoda za statistiku* (DZS) u tablici 6.6 prikazan je broj poduzeća prema veličini poduzeća za podatke prikupljene


anketom i za podatke preuzete iz priopćenja "Strukturno-poslovni pokazatelji poduzeća u 2012. Državnog zavoda za statistiku [73]. U zadnjem redu tablice prikazan je udio poduzeća obuhvaćenih anketom, u promilima (‰), u odnosu na aktivna poduzeća (iste veličine) nefinancijskog poslovnog gospodarstva RH u 2012. preuzetih iz DZS.

Tablica 6.6. Broj poduzeća prema veličini poduzeća

izvor podataka	broj poduzeća	Broj poduzeća prema veličini poduzeća				
		srednja i mala poduzeća (SMP)				velika (250 +)
		ukupno (mikro, mala, srednja)	mikro (<10)	mala (10 - 49)	srednja (50 - 249)	
		broj poduzeća	broj poduzeća	broj poduzeća	broj poduzeća	broj poduzeća
DZS (2012.)	148.573	148.127	136.092	10.252	1.783	446
anketa	176	153	62	48	43	23
obuhvaćeno anketom ‰	1,18	1,03	0,46	4,68	24,12	51,57

Iz podataka u tablici 6.6 vidi se da su provedenom anketom s najvećim udjelom obuhvaćena velika poduzeća (51,57 ‰), a najmanjim mikropoduzeća (0,46 ‰).

U europskoj ekonomiji, prema podacima u literaturi [74], mikro, mala i srednje velika poduzeća imaju središnju ulogu. Ona su ključni izvor zaposlenja, stvaraju poduzetnički duh i inovacije u EU i zbog toga su nužna za njegovanje konkurentnosti i održavanje zaposlenosti. U Europskoj je uniji oko 23 milijuna mikro, malih i srednje velikih poduzeća koja osiguravaju oko 75 milijuna radnih mjesta i predstavljaju 99 % svih postojećih poduzeća.



Slika 6.7. Udjeli prema veličini poduzeća u 2012. (podaci DZS) [73]

Na slici 6.7 vidi se da je udio aktivnih mikro, malih i srednje velikih poduzeća u 2012. u RH iznosio 99,7 %, što je više od prosjeka EU (99,0 %). Udio mikro, malih i srednje velikih poduzeća obuhvaćenih anketom iznosi 86,9 % (153/176) i manji je od prosjeka u RH i EU zbog relativno malog uzorka. Uzorak od 176 različitih poduzeća odgovara veličini oko 1,18 ‰ ukupnog broja aktivnih poduzeća, od 148.573 poduzeća, nefinancijskog poslovnog gospodarstva RH u 2012. (tablica 6.6).

6.3.1.2. Klasifikacija prema djelatnosti poduzeća

Prema *Nacionalnoj klasifikaciji djelatnosti* (NKD), verzija 2007., poduzeća koja su prema glavnoj djelatnosti svrstana u područja B do J i L do N te odjeljak 95 područja S spadaju u "nefinancijsko poslovno gospodarstvo" Republike Hrvatske. Riječ je o djelatnostima industrije, građevinarstva, trgovine i nefinancijskih usluga, koje najvećim dijelom čine tzv. realni sektor. Navedena područja i odjeljci NKD 2007. prikazani su u tablici 6.7 [73].


Tablica 6.7. Odabrane djelatnosti nefinancijskog poslovnog gospodarstva RH [73]

Područje / odjeljak		Naziv
industrija	B	Rudarstvo i vađenje
	C	Prerađivačka industrija
	D	Opskrba električnom energijom, plinom, parom i klimatizacija
	E	Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša
građevinarstvo	F	Građevinarstvo
trgovina	G	Trgovina na veliko i malo; popravak motornih vozila i motocikala
nefinancijske usluge	H	Prijevoz i skladištenje
	I	Djelatnosti pružanja smještaja te pripreme i usluživanja hrane
	J	Informacije i komunikacije
	L	Poslovanje nekretninama
	M	Stručne, znanstvene i tehničke djelatnosti
	N	Administrativne i pomoćne uslužne djelatnosti
	S95	Popravak računala i predmeta za osobnu uporabu i kućanstvo

Podaci prikupljeni anketom na osnovu tablice 6.7 klasificirani su u četiri grupe:

- Industrija
- Građevinarstvo
- Trgovina
- Nefinancijske usluge

Kao i kod klasifikacije po veličini poduzeća i klasifikacija prema djelatnosti poduzeća rađena je samo na 176 različitih anketiranih poduzeća, a prikazana je slikom 6.8. Vidi se da su najvećim djelom obuhvaćene djelatnosti industrije (43,2 %), a nešto manjim djelatnosti nefinancijskih usluga (35,8 %). Udio trgovačkih djelatnosti anketiranih poduzeća je 17,0 %, dok je najmanji udio poduzeća građevinskog sektora od 4,0 %.



Slika 6.8. Broj i udjeli poduzeća prema djelatnosti poduzeća


6.3.1.3. Klasifikacija prema sudionicima istraživanja

Sudionici istraživanja, prema literaturi [18], klasificirani su u četiri grupe:

- vrhovni menadžment predstavljaju: predsjedavajući upravnog odbora, predsjednik ili direktor, glavni izvršni direktor, glavni operativni direktor i potpredsjednik
- srednji menadžment predstavljaju: direktori poslovne jedinice, voditelji službe i voditelji odjela

- prva razina menadžmenta uključuje: nadzornike, menadžere ureda, voditelje smjene i poslovođe
- operativna razina – radnici poduzeća.

Na slici 6.9 prikazana je klasifikacija prikupljenih anketa prema sudionicima istraživanja. Oko 60,4 % od anketiranih osoba pripada rukovodećem kadru (vrhovni menadžment, srednji menadžment i prva razina menadžmenta), koji su ujedno i bili ciljana grupa ispitanika.




Slika 6.9. Klasifikacija prema sudionicima istraživanja

6.3.2. Analiza rezultata provedenog istraživanja prema anketnim pitanjima

6.3.2.1. Testiranje razumijevanja vitke filozofije (anketna pitanja: 1., 2. i 3.)

➤ *Pitanje 1: Kada govorite o učinkovitom upravljanju poduzećem, mislite li na?*

Ovim pitanjem nastoji se dobiti slika o sudionicima istraživanja s gledišta da li prepoznaju potencijal koji im nosi implementacija vitkih alata. Slika 6.10 daje rezultate usporedbe provedenog istraživanja u hrvatskim poduzećima s rezultatima istraživanja inozemnih autora.



Slika 6.10. Asocijacije s vitkom filozofijom: a.) hrvatska poduzeća, b.) inozemna poduzeća [11]

U literaturi se navedene izjave, osim prve (metoda smanjenja broja zaposlenih), navode kao aspekti vitke filozofije [11].

Podrška i uključenost menadžmenta navodi se u literaturi kao jedna od glavnih pretpostavki za uspješnu provedbu učinkovitoga upravljanja, odnosno vitke filozofije, dok svega oko 12 % ispitanika pridaje tome važnost. Također i vrlo mali broj ispitanika, njih oko 33 %, smatra da je učinkovito upravljanje način kreiranja novog načina rada i poslovanja. Najviše ispitanika, njih oko 77 %, na učinkovito upravljanje poduzećem asociraju izjave timski rad i kontinuirano unaprjeđenje i skup tehnika za unaprjeđenje proizvodnje/usluge i operacija.

Na osnovi navedenog te analizom ostalih izjava ispitanika (slika 6.10. a.) vidi se da velik broj ispitanika ne prepoznaje prave vrijednosti, prednosti i način vitkog načina razmišljanja.

Prema literaturi [11] i analizom izjava provedenog istraživanja u vitkim poduzećima automobilske industrije (slika 6.10. b.), autor zaključuje sljedeće:

- Oko 10 % ispitanika smatra da u vitku filozofiju spada metoda za smanjenje broja zaposlenih. Naravno da se pojedini alati vitke metodologije mogu primijeniti za analiziranje viškova (poput Jidoka ili taktno vrijeme), ali je osnova vitke filozofije primjena tih sredstava za daljnji napredak i rast.
- Još je jedno zanimljivo stajalište to da samo 42 % ispitanika smatra da je vitka filozofija način kreiranja novog načina rada i poslovanja. Gledajući na činjenicu da je smanjenje vodećeg vremena jedan od glavnih ciljeva vitke filozofije, može se reći da još veliki broj ispitanika ne vidi potencijal koji im nosi implementacija vitkih alata.
- 68 % ispitanika vidi vitku filozofiju kao potpuno integriranu psihologiju menadžmenta, dok je u teoriji prikazano kako je to jedna od glavnih pretpostavki za uspjeh i održivost.

Statistički test proporcija primjenjuje se za usporedbu dva uzorka. Ako je vjerojatnost odbacivanja nulte hipoteze " p " manja 0,05, tada je ona statistički znatna, a ako je veća od 0,05 ili jednaka s njom tada je statistički neznatna (na razini znatnosti od 5 %).

Statističkim testom proporcija testirale su se proporcije anketa provedenih u hrvatskim poduzećima i u inozemstvu (vitkim poduzećima automobilske industrije) vezane uz

asocijaciju s vitkom filozofijom. U tablici 6.8 prikazani su rezultati testa proporcija uzoraka, na osnovi kojih se može zaključiti sljedeće:


- Proporcije vezane uz asocijacije s vitkom proizvodnjom uglavnom se statistički znatno razlikuju za istraživanje provedeno u hrvatskim poduzećima i ono provedeno u inozemnim poduzećima koja su implementirala vitku filozofiju [11].
- Jedino za izjave "način kreiranja novog načina rada" i "sustav za organiziranje i upravljanje razvojem proizvoda/usluga, operacija, nabave i odnosa s kupcima" test proporcija je pokazao da su razlike u percepcijama sudionika istraživanja statistički neznatne između provedenih istraživanja u hrvatskim poduzećima i u inozemnim poduzećima koja su implementirala vitku filozofiju [11].

Tablica 6.8. Test proporcija uzoraka – asocijacije s vitkom filozofijom

Izjava	<i>p</i>	Statistički
metoda smanjenja broja zaposlenih	0,0148	znatna
sustav reorganizacije poduzeća po vrstama proizvoda/usluga i po vrijednosti	< 0,0001	znatna
potpuno integrirana psihologija menadžmenta	< 0,0001	znatna
psihologija koja je potpuno usmjerena na kupce/klijente	< 0,0001	znatna
način kreiranja novog načina rada i poslovanja	0,0899	neznatna
sustav za proizvodnju proizvoda s malo grešaka	0,0007	znatna
stalno smanjenje nepotrebnih zadataka	< 0,0001	znatna
sustav za organiziranje i upravljanje razvojem proizvoda/usluga, operacija, nabave i odnosa s kupcima	0,1949	neznatna
timski rad i kontinuirano unaprjeđenje	0,0037	znatna
skup tehnika za unaprjeđenje proizvodnje/usluge i operacija	0,0037	znatna

➤ *Pitanje 2: Procijenite koja od sljedećih tvrdnji najviše utječe na uspješnost nekog poduzeća. Rangirajte navedene tvrdnje prema važnosti utjecaja.*

Slika 6.11 prikazuje tvrdnje koje utječu na uspješnost poslovanja poduzeća rangirane prema važnosti utjecaja. Prema mišljenju sudionika istraživanja vrlo visok utjecaj na uspješnost poduzeća imaju vještine i stručnost zaposlenika, dok najmanji utjecaj ima raspoloživost financijskih sredstava.



Slika 6.11. Utjecaj na uspješnost poduzeća


Radi usporedbe s istraživanjem provedenima na financijskim institucijama u Južnoj Africi koje primjenjuju vitku filozofiju, prema literaturi [68] za rangiranje tvrdnji po važnosti utjecaja koji utječu na uspješnost poslovanja poduzeća (slika 6.12.a.), upotrijebljene su samo tvrdnje iz slike 6.11 koje su sudionici istraživanja rangirali kao one s vrlo visokim utjecajem.

Iako se radi o različitim vrstama djelatnosti poduzeća i o sudionicima istraživanja iz različitih država, usporedbom podataka istraživanja (slika 6.12) provedenog u RH i u Južnoj Africi zaključuje se sljedeće:

- Vještine i stručnost zaposlenika, prema sudionicima istraživanja, i u RH i u Južnoj Africi, imaju vrlo visok utjecaj na uspješnost poduzeća.
- Na drugom mjestu u RH nalazi se razrađena poslovna strategija, a na trećem uključenost i podrška menadžmenta, dok su za istraživanje provedeno u

financijskim institucijama u Južnoj Africi ove tvrdnje rangirane obrnutim redoslijedom.

- Zanimljivo je i stajalište ispitanika istraživanja u Južnoj Africi da raspoloživost financijskih sredstava ne utječe na uspješnost poduzeća, dok je 9 % sudionika istraživanja u RH ovoj tvrdnji pripisalo vrlo velik utjecaj na uspješnost poduzeća.



Slika 6.12. Utjecaj na uspješnost poduzeća: a.) hrvatska poduzeća, b.) inozemna poduzeća [68]

Za usporedbu anketa provedenih u hrvatskim poduzećima i onih u inozemstvu (vitkim financijskim institucijama u Južnoj Africi) [68], vezanih uz utjecaj na uspješnost poduzeća, primijenjen je i test proporcija uzoraka. Rezultati testa proporcija prikazani su u tablici 6.9.

Budući da je inozemna anketa rađena na malom uzorku (20 uzoraka), rezultate testa proporcija potrebno je uzeti s određenom rezervom. Analizom rezultata testa proporcija zaključuje se sljedeće:

- Razlike u percepcijama sudionika istraživanja, vezane uz izjave o utjecaju na uspješnost poduzeća, statistički su neznatne između provedenih istraživanja u hrvatskim poduzećima i inozemnim vitkim financijskim institucijama u Južnoj Africi [68], osim što se tiče izjave "raspoloživost financijskih sredstava".

- Proporcije vezane uz "raspoloživost financijskih sredstava" statistički se znatno razlikuju za istraživanje provedeno u hrvatskim poduzećima i inozemnim vitkim financijskim institucijama u Južnoj Africi [68].

Tablica 6.9. Test proporcija uzoraka – utjecaj na uspješnost poduzeća

Izjava	<i>p</i>	Statistički
raspoloživost financijskih sredstava	< 0,0001	znatna
dobra komunikacija na svim razinama unutar poduzeća	0,3985	neznatna
kontinuirano ulaganje u razvoj poduzeća	0,0701	neznatna
uključenost i podrška menadžmenta	0,2849	neznatna
razrađena poslovna strategija	0,0729	neznatna
vještine i stručnost zaposlenika	0,4498	neznatna

➤ *Pitanje 3: Vaše poduzeće investiralo bi u povećanje učinkovitosti poslovanja radi?*


Odgovorima na ovo pitanje, od sudionika istraživanja, želi se vidjeti jesu li razlozi radi kojih bi oni investirali u povećanje učinkovitosti poslovanja poduzeća po načelima vitke filozofije.

Kao što je prikazano slikom 6.13. a.), neznatno iznad, 81 % sudionika istraživanja investiralo bi u povećanje učinkovitosti poslovanja poduzeća radi postizanja kompetitivne prednosti u cijeni i usluzi, dok bi najmanji broj njih (oko 27 %) investirao radi stalnog pritiska za unaprjeđenjem operacija.

Slikom 6.13. b.) prikazana je klasifikacija razloga primjene vitkih načela od strane sudionika istraživanja koji rade u vitkim poduzećima u automobilske industriji [11].

- Oko 83 % sudionika istraživanja navelo je stalni pritisak za unaprjeđenjem poslovnih procesa, odnosno poboljšanjem operativne učinkovitosti, kao glavni razlog za primjenu vitkih načela.
- Također se vidi da je i disperzija ostalih čimbenika između 60 i 80 %.

- Između ostalog, zanimljivo je da je 68 % sudionika istraživanja navelo smanjenje cijene kupcima kao razlog primjene vitkih načela. Prema literaturi to je obrnuto od vitke filozofije u kojoj se treba zapitati koliko je kupac spreman platiti, a onda automatski smanjiti gubitke kako bi se ponudila konkurentna cijena.



Slika 6.13. Razlozi investiranja u povećanje učinkovitosti poslovanja poduzeća radi:

a.) hrvatska poduzeća, b.) inozemna poduzeća [11]

Za usporedbu anketa provedenih u hrvatskim poduzećima i u inozemstvu (u vitkim poduzećima, u automobilske industriji) [11], vezanih uz razloge investiranja u povećanje učinkovitosti poslovanja poduzeća, primijenjen je i test proporcija uzoraka. Rezultati testa proporcija prikazani su u tablici 6.10.

Tablica 6.10. Test proporcija uzoraka – razlozi investiranja u povećanje učinkovitosti poduzeća radi

Izjava	<i>p</i>	Statistički
postizanja kompetitivne prednosti u cijeni i usluzi	0,0014	znatna
povećanja profita	0,2987	neznatna
kraćeg roka isporuke kupcima	0,0007	znatna
smanjenja cijene kupcima	< 0,0001	znatna
stalnog pritiska za unapređenjem operacija	< 0,0001	znatna

Na osnovi rezultata testa proporcija uzoraka zaključuje se:


- Proporcije vezane uz razloge investiranja u povećanje učinkovitosti poslovanja poduzeća uglavnom se statistički znatno razlikuju za istraživanje provedeno u hrvatskim poduzećima i ono provedeno u inozemnim poduzećima.
- Test proporcija pokazao je da su razlike u opažanjima sudionika istraživanja statistički neznatne između provedenih istraživanja u hrvatskim poduzećima i u inozemnim poduzećima jedino u onom slučaju ako je razlog investiranja u povećanje učinkovitosti poslovanja poduzeća "povećanje profita".

Prethodno navedeno dovodi do spoznaje da su razlozi investiranja u povećanje učinkovitosti poslovanja u hrvatskim poduzećima u potpunoj suprotnosti (gotovo inverzni) u odnosu na iste razloge kod anketiranih vitkih poduzeća obrađenih u literaturi [11] (slika 6.13, tablica 6.10).

6.3.2.2. Komunikacija kod provedbe projekata (anketna pitanja: 4. i 5.)

➤ *Pitanje 4: Da li djelatnost Vašeg poduzeća uglavnom ovisi o Vašim dobavljačima (kooperantima)? Navedite na koji način/kojim sredstvima komuniciranja uspostavljate kontakt s dobavljačima (kooperantima)?*

Često čujemo izreku *lanac je jak koliko i njegova najslabija karika*, a ona vrijedi i u poslovnom okruženju. Navedenim pitanjima želi se vidjeti u kojoj mjeri hrvatska poduzeća ovise o svojim dobavljačima (kooperantima) jer, da bi se postalo vitko poduzeće, potrebno je i da ostale "karike lanca" primjenjuju vitka načela.




Slika 6.14. Ovisnost poduzeća o dobavljačima (kooperantima)

Prema ispitanicima oko 55 % anketiranih hrvatskih poduzeća ovisi o svojim dobavljačima (slika 6.14), a kao glavne načine komunikacije s dobavljačima primjenjuju internet (89 %) i telefon/fax (83 %). Kao jedan od načina komunikacije s dobavljačima (kooperantima) u 32 % slučajeva naveden je posebni programski alat, npr. mrežni program (slika 6.15).

Na pitanje otvorenog tipa, navedeno pod "ostalo", od 11 sudionika ispitivanja (11/153 ekvivalent oko 7 %) dobiveni su odgovori poput:

- javna nabava
- pošta, dopisi
- posjet dobavljačima, direktni kontakt
- sajmovi.



Slika 6.15. Način komunikacije s dobavljačima (kooperantima)

Na slici 6.15 prikazano je da od poduzeća koja ovise o svojim dobavljačima (kooperantima) njih 32 % međusobno komunicira s pomoću posebnog programskog alata. Taj postotak nije velik i svakako predstavlja potencijal za poboljšanje komunikacije među poslovnim partnerima.


➤ *Pitanje 5: Procijenite na skali od 1 do 5 sljedeće tvrdnje koje se odnose na komunikaciju kod provedbe projekta?*

Cilj je ovog pitanja s pomoću navedenih tvrdnji saznati kakva je komunikacija kod provedbe projekta, ne samo unutar poduzeća nego i izvan njega, s ostalim sudionicima projekta poput dobavljača, kooperanata i sl.

Slikom 6.16. a.) prikazana je procjena aktivnosti u komunikaciji kod provedbe projekta. Prema sudionicima istraživanja komunikaciji unutar poduzeća kod provedbe projekta (odnosi se na prve tri tvrdnje) pripisuje se uglavnom aktivnost od 74 % do 81 % (razmatran samo prosječan, visok i vrlo visok stupanj aktivnosti). Komunikaciji sa ostalim sudionicima projekta (npr. dobavljačima) pripisan je manji stupanj aktivnosti, točnije 68 %.

Komunikacijski stavovi financijskih institucija u Južnoj Africi koje primjenjuju vitku filozofiju prikazani su slikom 6.16. b.).

Usporedbom rezultata istraživanja (slika 6.16) zaključuje se da je komunikacija kod provedbe projekta (razmatrane samo prosječne, visoke i vrlo visoke aktivnosti) gotovo za sve navedene tvrdnje, osim za "većina zaposlenih razumije projekt i koji se cilj želi postići", bolja u poduzećima koja primjenjuju vitku filozofiju.



Slika 6.16. Komunikacija kod provedbe projekta: a.) hrvatska poduzeća, b.) inozemna poduzeća [68]

Za usporedbu anketa provedenih u hrvatskim poduzećima i u inozemstvu (vitkim financijskim institucijama u Južnoj Africi) [68], vezanih uz komunikaciju kod provedbe projekata, primijenjen je i test frekvencija uzoraka (hi-kvadrat test), kako bismo ustanovili razlikuju li se uzorci u opaženim svojstvima. Rezultati testa frekvencija uzoraka prikazani su u tablici 6.11.

Zbog malog uzorka na kojem je rađena inozemna anketa (20 uzoraka) rezultate testa frekvencija uzoraka potrebno je uzeti s određenom rezervom. Test frekvencija uzoraka dovodi do zaključka da se razmatrani uzorci (hrvatskih i inozemnih poduzeća) razlikuju statistički znatno, a i struktura odgovora potpuno je različita (slika 6.16).

Tablica 6.11. Test frekvencija uzoraka – komunikacija kod provedbe projekata

Izjava	<i>p</i>	Statistički
projekt ima komunikacijski plan	< 0,0001	znatna
projekt ima definiranu komunikaciju s poslovnim jedinicama	< 0,0001	znatna
većina zaposlenih razumije projekt i koji se cilj želi postići	< 0,0001	znatna
svi dioničari efikasno i kontinuirano komuniciraju o svrsi projekta i cilju	< 0,0001	znatna

6.3.2.3. Primjena alata i tehnika vitke metodologije (anketno pitanje: 6.)

➤ *Pitanje 6: Odaberite alat koji se primjenjuje u Vašem poduzeću da biste postali učinkovitije poduzeće?*

Ovim pitanjem analizira se primjena vitkih alata u poduzeću tako da za navedene vitke alate ispitanici navedu koji se vitki alat primjenjuje i gdje u poduzeću npr.: samo lokalno, u cijelom poduzeću ili i izvan poduzeća uključujući kupce i dobavljače.

Odgovor na ovo pitanje nije dalo 11 sudionika istraživanja, što je ekvivalent od 3,9 %.


U kojoj se mjeri navedeni alati primjenjuju u hrvatskim poduzećima kako bi ona postala što učinkovitija poduzeća prikazano je na slici 6.17. a). Prema sudionicima istraživanja:

- Najviše se primjenjuju sljedeći alati: mapiranje procesa 78 %, 5S alat 77 %, tijekom proizvodnje / usluge 75 % te vrijeme obrade i standardizacija 67 %.
- Alati koji se najmanje primjenjuju jesu: KANBAN ne primjenjuje 41 % poduzeća, SMED 40 %, TPM 39 %, dok šest sigma ne primjenjuje 37 % poduzeća.

Na pitanje otvorenog tipa, navedeno pod "ostalo", od 7 sudionika ispitivanja (7/269 odnosno oko 2,6 %) dobiveni su odgovori poput:

- SSP Billing
- ICS – Internal Control System
- HACCI

- Everest program
- TQM, FMEA, MSA, SPC, APQP, Sustav internih audita.



Slika 6.17. Primjena specifičnih alata u poduzeću radi postizanja učinkovitijeg poduzeća: a.) hrvatska poduzeća, b.) inozemna poduzeća [11]

Vitki alati i u kojoj mjeri se primjenjuju u vitkim poduzećima, za provedeno istraživanje u poduzećima automobilske industrije, prikazani su na slici 6.17. b.) [11].

- Kao najvažniji alat "mapiranje procesa" navodi 84 % sudionika istraživanja. Štoviše to je jedini alat koji se znatno (više od 5 %) primjenjuje izvan poduzeća, točnije preko 8 % kod kupaca i dobavljača.
- 40 % ispitanika navelo je "šest sigma" kao alat koji se ne primjenjuje.
- Primjena ostalih vitkih alata je: 95 % primjenjuje 5S program, 84 % tijekom proizvodnje, taktno vrijeme te standardizaciju i SMED, dok 92 % primjenjuje KANBAN.

Usporedbom rezultata istraživanja (slika 6.17) može se zaključiti:

- Da 17 do 45 sudionika istraživanja u hrvatskim poduzećima za pojedini ponuđeni alat nije navelo primjenu u poduzeću u kojem su zaposleni, što je ekvivalent od 6 % do 16 %. Kod istraživanja provedenog na zaposlenicima vitkih poduzeća [11] taj je postotak znatno niži i kreće se do 5 %. Uzrok je tome najvjerojatnije to što navedeni sudionici istraživanja hrvatskih poduzeća nisu upoznati s vitkom terminologijom.
- Oba istraživanja dovela su do zaključka da se "mapiranje procesa" najčešće primjenjuje kao alat za povećanje učinkovitosti poduzeća.
- Zanimljivo je da je u oba istraživanja, s vrlo sličnim postotkom (37 % odnosno 40 %), naveden "šest sigma" kao alat koji se ne primjenjuje.
- Znatno je veća primjena alata KANBAN 48 %, SMED 33 % i TPM 20 % u navedenom primjeru vitkih poduzeća u odnosu na anketirana hrvatska poduzeća.

Za usporedbu anketa provedenih u hrvatskim poduzećima i onih u inozemstvu (vitkim poduzećima automobilske industrije) [11], vezanih uz primjenu specifičnih alata u poduzeću radi postizanja učinkovitijeg poduzeća, kako bi ustanovili razlikuju li se uzorci u opaženim svojstvima primijenjen je test frekvencija uzoraka (hi-kvadrat test).

Rezultati testa frekvencija uzoraka prikazani su u tablici 6.12, na osnovi kojih se zaključuje da se razmatrani uzorci (hrvatskih i inozemnih poduzeća) za sve navedene vitke alate razlikuju statistički znatno i da je struktura odgovora potpuno različita (slika 6.17).


Tablica 6.12. Test frekvencija uzoraka – primjena specifičnih alata u poduzeću radi postizanja učinkovitijeg poduzeća

Izjava	<i>p</i>	Statistički
mapiranje procesa (međusobno dovodenje u vezu svih aktivnosti, procesa, tokova - materijala i informacija, i sl.)	< 0,0001	znatna
5S red, urednost, nezagađenost, čistoća, disciplina; čisto i sigurno radno okruženje	< 0,0001	znatna
tijek proizvodnje / usluge	< 0,0001	znatna
vrijeme obrade i standardizacija	< 0,0001	znatna
SMED (brza promjena alata, smanjenje vremena proizvodnje / usluge)	< 0,0001	znatna
KANBAN (sustav smanjenja zaliha u proizvodnji / usluzi), standardni materijali	< 0,0001	znatna
šest sigma - skup metodoloških principa i statističkih alata za kontinuirano poboljšanje procesa	< 0,0001	znatna
TPM - cjelovito produktivno održavanje	< 0,0001	znatna

6.3.2.4. Potencijali za smanjenje gubitaka u poduzeću (anketno pitanje: 7.)

➤ *Pitanje 7: Prema LEAN metodologiji postoji 7+1 vrsta gubitaka u poslovanju poduzeća. Na svakom pitanju (1 – 8) odaberite jedan ili više ponuđenih gubitaka (a, b, c ili d) koji se pojavljuju u Vašem poduzeću te odgovorite koliki je potencijal za smanjenje tog gubitka u Vašem poduzeću?*

Na ovo pitanje 7 sudionika istraživanja nije dalo odgovor (2,5 %) dok je postotak nedobivenih odgovora prema pojedinim vrstama gubitaka znatno veći (slika 6.18).




Slika 6.18. Postotak nedobivenih odgovora prema vrstama gubitaka prema LEAN metodologiji


Na slici 6.19 i 6.20 prvi stupac s desne strane označava postotak (od 15 % do 49 %) nedobivenih odgovora. Unatoč tako velikom postotku nedobivenih odgovora, na osnovi prikupljenih podataka (slika 6.19), zaključeno je sljedeće:

- Kao glavni gubici "prekomjerne proizvodnje" navedeni su: slanje uputa na previše (premalo) ljudi (s potencijalom za smanjenje gubitaka od 62 %) i stvaranje dokumentacije koju nitko ne treba (s potencijalom od 59 % za smanjenje gubitaka), dok proizvodnja za "svaki slučaj" ima najmanji potencijal (35 %) za smanjenje gubitka prekomjerne proizvodnje.
- Gubitak "više materijala i informacija nego što je potrebno", prema sudionicima istraživanja, predstavlja 60 %-tni potencijal za smanjenje gubitaka "zalihe".

- Neučinkovito i nepotrebno kretanje informacija predstavlja potencijal od 66 % dok najmanji potencijal od 43 % ima nepotrebno kretanje materijala (obradaka) za smanjenje gubitaka "transporta" u poslovanju poduzeća.
- Daleko najveći potencijal od 71 % za smanjenje gubitaka u poslovanju poduzeća "čekanje" predstavlja čekanje na podatke, informacije, odluke, potpis, odobrenje i sl.



Slika 6.19. Potencijal smanjenja gubitaka: prekomjerne proizvodnje, zaliha, transporta, čekanja



Slika 6.20. Potencijal smanjenja gubitaka: nepotrebnih kretanja, škarta, prekomjerne obrade, nedovoljnog korištenja potencijala radnika

Analizom slike 6.20 može se zaključiti:

- Na navedenom gubitku "Ručni rad kako bi se kompenzirali nedostaci procesa" postoji, prema sudionicima istraživanja, potencijal od 54 % za smanjenje gubitaka poslovanja poduzeća "nepotrebna kretanja".

- Potencijal od 71 % za smanjenje gubitaka poslovanja poduzeća "škart" je u: prekidu toka zbog grešaka, nepotrebnom vremenu, troškovima i prostoru za analizu i otklanjanje nepotpune, netočne i nepravodobne informacije.
- Kriva ili nedostajuća tehnološka oprema glavni je uzrok gubitaka u poslovanju poduzeća "prekomjerna obrada", pa na njoj postoji potencijal od 53 % za smanjenje navedenog gubitka.
- Zbog toga što se radnike ne uključuje u aktivnosti poboljšanja procesa postoji potencijal od 66 % za smanjenje gubitka poslovanja poduzeća "nedovoljno korištenje potencijala radnika".

7. ANALIZA ZNATNOSTI UTJECAJA POKAZATELJA PODUZEĆA

Analiza prikupljenih podataka obrađena u prethodnom poglavlju (poglavlje 6.) provedena je na cjelokupnom uzorku od 280 prikupljenih anketa. Analizom se zaključilo da velik broj sudionika istraživanja ne prepoznaje prave vrijednosti, prednosti i način vitkog načina razmišljanja. Također se vidi da postoji bitna razlika u razmišljanjima sudionika istraživanja provedenog u hrvatskim i inozemnim vitkim poduzećima u vezi s primjenom alata vitke metodologije.

Radi analize problema da li se odgovori sudionika istraživanja provedenog u hrvatskim poduzećima razlikuju znatno ili ne prema pojedinim pokazateljima poduzeća, u nastavku rada statistički su obrađeni prikupljeni podaci prema pokazateljima poduzeća:

- veličini poduzeća (mikro, mala, srednje velika i velika)
- djelatnosti poduzeća (proizvodna, uslužna)
- radnom mjestu sudionika istraživanja (vrhovni menadžment, srednji menadžment, prva razina menadžmenta i operativna razina).

Programskim paketom *Statistica* tvrtke *StatSoft* prema pokazateljima poduzeća statistički su obrađeni anketom prikupljeni podaci o primjeni alata i tehnika vitke metodologije (anketno pitanje: 6.) te potencijali za smanjenje gubitaka poslovanja poduzeća (anketno pitanje: 7.).

Budući da su relativno mali uzorci prikupljenih podataka prema pojedinim pokazateljima poduzeća, a za rangiranje je primijenjena kategorijska skala mjerenja te nisu postavljeni nikakvi zahtjevi na distribuciju izvornih podataka, kod statističke obrade podataka primijenjeni su neparametrijski testovi. Ovisno o broju nezavisnih uzoraka, kod statističke obrade podataka primijenjeni su: [76]

- *Mann-Whitney U test* – neparametrijski test, koji se primjenjuje za usporedbu između dva nezavisna uzorka koji su uzeti iz iste populacije.
- *Kruskal-Wallis analiza varijance rangova (H-test)* – neparametrijski test, koji se primjenjuje za usporedbu između više od dva nezavisna uzorka koji su uzeti iz iste populacije.
- *Medijan test* – neparametrijski test, koji se primjenjuje za usporedbu između više od dva nezavisna uzorka koji su uzeti iz iste populacije.

Statistička obrada podataka prikupljenih anketnim pitanjima 6. i 7., prema navedenim pokazateljima poduzeća, navedena je u nastavku.

7.1. Primjena alata i tehnika vitke metodologije u hrvatskim poduzećima

Testom frekvencija uzoraka (tablica 6.12), vezanog uz primjenu alata i tehnika vitke metodologije, između anketa provedenih u hrvatskim poduzećima i u inozemstvu (vitkim poduzećima automobilske industrije) [11] došlo se do zaključka da se razmatrani uzorci (hrvatskih i inozemnih vitkih poduzeća) za sve navedene vitke alate razlikuju statistički znatno i da je struktura odgovora potpuno različita.

Znatnost utjecaja pokazatelja poduzeća (veličina poduzeća, djelatnost poduzeća, radno mjesto sudionika istraživanja) na primjenu alata i tehnika vitke metodologije u hrvatskim poduzećima analizirana je u nastavku.

7.1.1. Analiza prema veličini poduzeća

Anketom prikupljeni podaci klasificirani su prema veličini poduzeća (poglavlje 6.3.1.1.) na: mikropoduzeća, mala poduzeća, srednje velika poduzeća i velika poduzeća. Budući da se radi o usporedbi četiri nezavisna uzorka, kod statističke obrade prikupljenih podataka prema veličini poduzeća primijenjeni su *Kruskal-Wallis analiza varijance rangova (H - test)* i *Medijan test*.

Provedenim *Kruskal-Wallis testom* (tablica 7.1) vidi se da je vjerojatnost odbacivanja nulte hipoteze " p " veća od 0,05 pa je statistički neznatna (na razini znatnosti od 5 %) po analiziranim vitkim alatima. Utjecaj veličine poduzeća, prema ovom testu, statistički je neznatan na primjenu alata i tehnika vitke metodologije u hrvatskim poduzećima.

Tablica 7.1. *Kruskal-Wallis test* – primjena vitkih alata – analiza prema veličini poduzeća

Vitki alat	broj uzoraka	<i>H</i> - test	<i>p</i>
mapiranje procesa	260	2,9536	0,3988
5 S	262	2,4927	0,4759
tijek proizvodnje / usluge	251	2,6343	0,4515
vrijeme obrade i standardizacija	236	1,5353	0,6741
SMED	242	2,2149	0,5290
KANBAN	238	0,1866	0,9797
šest sigma	244	4,03566	0,2576
TPM	241	1,8517	0,6037

Provedenim *Medijan testom* (tablica 7.2) vidi se da je vjerojatnost odbacivanja nulte hipoteze "*p*" manja od 0,05 pa je statistički znatna (na razini znatnosti od 5 %) za vitki alat "mapiranje procesa". Za ostale analizirane vitke alate vjerojatnost odbacivanja nulte hipoteze "*p*" veća je od 0,05 te je statistički neznatna (na razini znatnosti od 5 %).

Tablica 7.2. *Medijan test* – primjena vitkih alata – analiza prema veličini poduzeća

Vitki alat	ukupni medijan	χ^2	<i>p</i>
mapiranje procesa	3	8,9111	0,0305
5 S	3	0,5931	0,8980
tijek proizvodnje / usluge	3	3,6112	0,3066
vrijeme obrade i standardizacija	3	4,7219	0,1931
SMED	2	5,8451	0,1194
KANBAN	2	1,2009	0,7528
šest sigma	2	5,4178	0,1436
TPM	2	3,5545	0,3138

Ukupno gledajući, iz ostalih rezultata provedenih testova (tablica 7.1 i 7.2) može se reći da je utjecaj pokazatelja poduzeća – veličina poduzeća, statistički neznatan na primjenu alata i tehnika vitke metodologije u hrvatskim poduzećima.

7.1.2. Analiza prema djelatnosti poduzeća

Prema klasifikaciji anketom prikupljenih podataka prema djelatnosti poduzeća (poglavlje 6.3.1.2.) vidi se da su najvećim djelom obuhvaćene djelatnosti industrije (43,2 %, odnosno 76 poduzeća), a nešto manjim djelatnosti nefinancijskih usluga (35,8 %, odnosno 63 poduzeća). Udio je trgovačkih djelatnosti anketiranih poduzeća 17,0 % (30 poduzeća), dok je najmanji udio poduzeća građevinskog sektora od 4,0 % (7 poduzeća).

Budući da je mali broj anketiranih poduzeća trgovačke djelatnosti (30 poduzeća) i poduzeća građevinskog sektora (7 poduzeća), zbog malog uzorka navedena klasifikacija prema djelatnosti poduzeća nije pogodna za statističku obradu. Stoga su anketom prikupljeni podaci, za daljnju analizu (statističku obradu), klasificirani prema djelatnosti poduzeća na:

- proizvodna poduzeća (industrija i građevinarstvo)
- uslužna poduzeća (nefinancijske usluge i trgovina)

Budući da se radi o usporedbi između dva nezavisna uzorka za statističku obradu prikupljenih podataka po djelatnosti poduzeća primijenjen je *Mann-Whitney U test*.

Provedenim *Mann-Whitney U testom* (tablica 7.3) vjerojatnost odbacivanja nulte hipoteze " p " veća je od 0,05 za vitke alate "mapiranje procesa" i "5 S" pa je statistički neznatna (na razini znatnosti od 5 %). Za ostale analizirane vitke alate vjerojatnost odbacivanja nulte hipoteze " p " manja je od 0,05 pa je statistički znatna (na razini znatnosti od 5 %). Prema ovom testu statistički znatan utjecaj ima pokazatelj poduzeća - djelatnost poduzeća na primjenu alata i tehnika vitke metodologije u hrvatskim poduzećima.

Tablica 7.3. *Mann-Whitney U test* – primjena vitkih alata – analiza prema djelatnosti poduzeća

Vitki alat	suma rangova uslužna	suma rangova proiz.	<i>U</i>	<i>p</i>	broj uslužnih	broj proiz.
mapiranje procesa	16112,0	17818,0	7727,0	0,2336	129	131
5 S	16301,5	18151,5	8173,5	0,5156	127	135
tijek proizvodnje / usluge	14258,5	17367,5	6383,5	0,0095	125	126
vrijeme obrade i standardizacija	12356,5	15609,5	5686,5	0,0153	115	121
SMED	12667,0	16736,0	5764,0	0,0044	117	125
KANBAN	11165,5	17275,5	4495,5	< 0,0001	115	123
šest sigma	13461,5	16428,5	6080,5	0,0135	121	123
TPM	10992,5	18168,5	4322,5	< 0,0001	115	126

7.1.3. Analiza prema radnom mjestu sudionika istraživanja

Anketom prikupljeni podaci klasificirani su prema radnom mjestu sudionika istraživanja (poglavlje 6.3.1.3.) na: vrhovni menadžment, srednji menadžment, prva razina menadžmenta i operativna razina. Budući da se radi o usporedbi četiri nezavisna uzorka podataka prikupljenih prema radnom mjestu sudionika istraživanja za statističku obradu, primijenjeni su *Kruskal-Wallis analiza varijance rangova (H - test)* i *Medijan test*.

Iz rezultata provedenih testova (tablica 7.4 i 7.5) vidi se da je vjerojatnost odbacivanja nulte hipoteze "*p*" veća od 0,05 pa je statistički neznatna (na razini znatnosti od 5 %). Može se reći da su razlike u odgovorima vezanim uz primjenu alata i tehnika vitke metodologije u hrvatskim poduzećima statistički neznatne o radnom mjestu sudionika istraživanja.

Tablica 7.4. *Kruskal-Wallis test* – primjena vitkih alata – analiza prema radnom mjestu sudionika istraživanja

Vitki alat	broj uzoraka	<i>H - test</i>	<i>p</i>
mapiranje procesa	260	0,5545	0,9068
5 S	262	5,3726	0,1465
tijek proizvodnje / usluge	251	2,4669	0,4813
vrijeme obrade i standardizacija	236	5,1982	0,1578
SMED	242	3,6057	0,3073
KANBAN	238	3,0541	0,3834
šest sigma	244	6,5651	0,0871
TPM	241	3,7296	0,2922

Tablica 7.5. *Medijan test* – primjena vitkih alata – analiza prema radnom mjestu sudionika istraživanja

Vitki alat	ukupni medijan	χ^2	<i>p</i>
mapiranje procesa	3	0,6735	0,8794
5 S	3	3,0087	0,3903
tijek proizvodnje / usluge	3	1,0452	0,7903
vrijeme obrade i standardizacija	3	7,6069	0,0549
SMED	2	4,8795	0,1808
KANBAN	2	4,3272	0,2282
šest sigma	2	6,5666	0,0871
TPM	2	4,7506	0,1910

7.2. Potencijal smanjenja gubitaka u poslovanju hrvatskih poduzeća

Analizom rezultata provedenog istraživanja (poglavlje 6.3.2) prema sudionicima istraživanja postoji prilično veliki potencijal za smanjenje gubitaka u poslovanju poduzeća (7 + 1 vrsta gubitaka prema vitkoj metodologiji). U nastavku rada statističkom obradom podataka prikupljenih anketom analizirana je znatnost utjecaja pokazatelja poduzeća (veličina poduzeća, djelatnost poduzeća, radno mjesto sudionika istraživanja) na potencijal smanjenja gubitaka u poslovanju hrvatskih poduzeća.

7.2.1. Analiza prema veličini poduzeća

Za statističku obradu podataka prikupljenih prema veličini poduzeća primijenjeni su *Kruskal-Wallis analiza varijance rangova (H - test)* i *Medijan test*, budući da se radi o usporedbi četiri nezavisna uzorka (mikropoduzeća, mala poduzeća, srednje velika poduzeća i velika poduzeća).

Iz provedenih testova (tablica 7.6 i 7.7) vidi se da je vjerojatnost odbacivanja nulte hipoteze " p " manja od 0,05 pa je statistički znatna (na razini znatnosti od 5 %) za potencijal smanjenja gubitaka u poslovanju poduzeća: prekomjerna proizvodnja, zalihe, transport i nepotrebna kretanja.

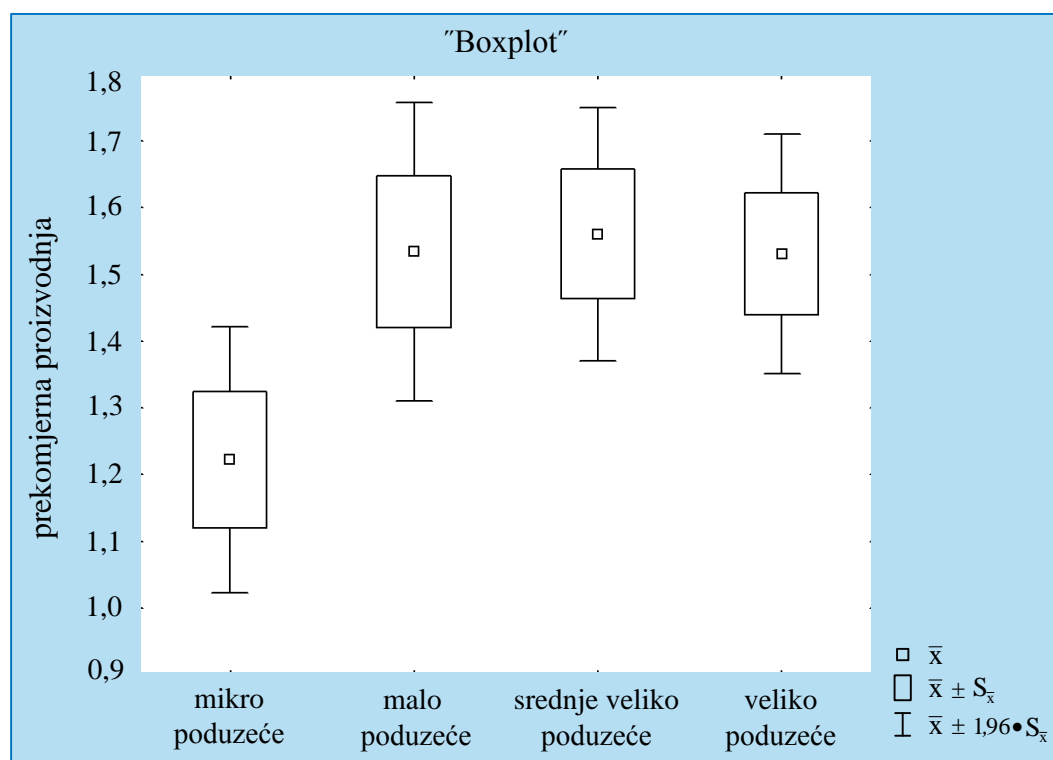
Tablica 7.6. *Kruskal-Wallis test* – potencijal smanjenja gubitaka – analiza prema veličini poduzeća

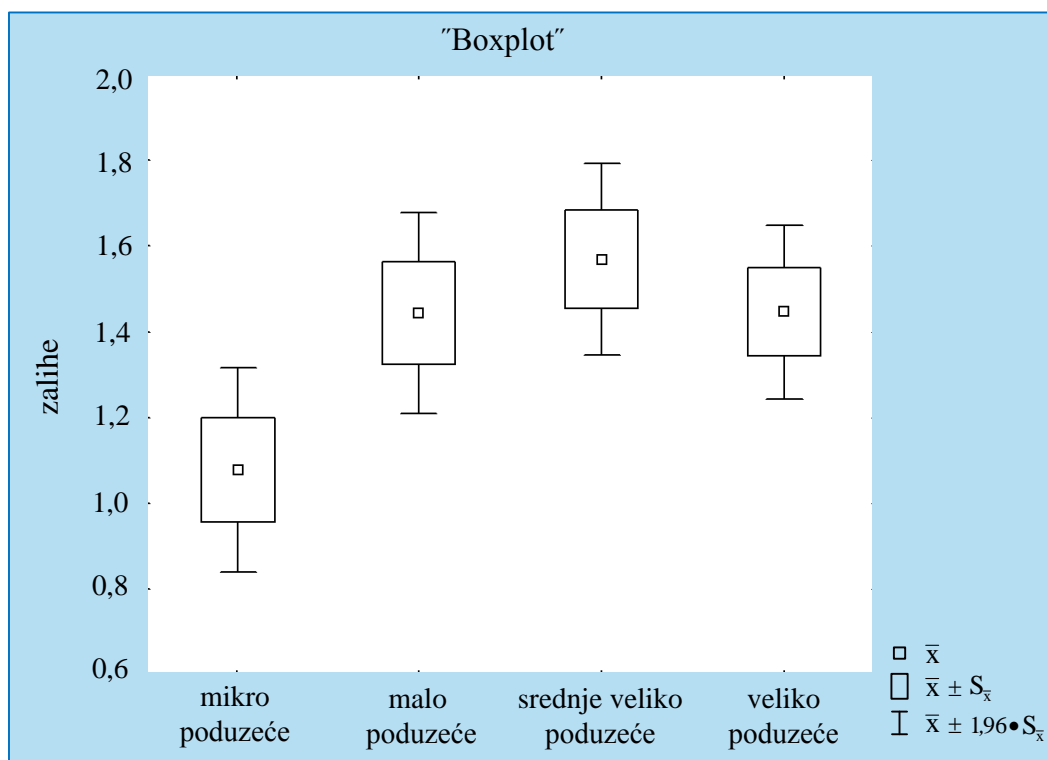
Gubitak u poslovanju poduzeća	broj uzoraka	<i>H - test</i>	<i>p</i>
prekomjerna proizvodnja	269	7,5099	0,0573
zalihe	255	10,4051	0,0154
transport	264	8,1259	0,0435
čekanje	266	6,8315	0,0775
nepotrebna kretanja	242	15,6503	0,0013
škart	237	5,0566	0,1677
prekomjerna obrada	238	2,2574	0,5207
nedovoljno korištenje potencijala radnika	251	6,1565	0,1042

Tablica 7.7. Medijan test – potencijal smanjenja gubitaka – analiza prema veličini poduzeća

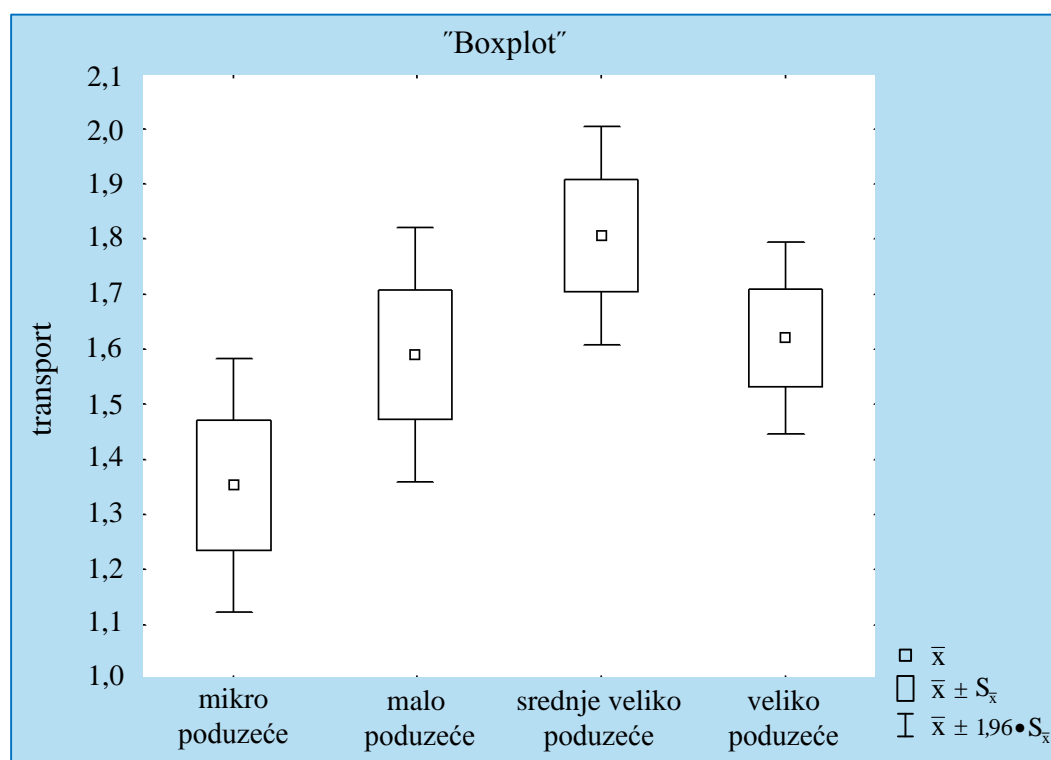
Gubitak u poslovanju poduzeća	ukupni medijan	χ^2	p
prekomjerna proizvodnja	1,50	9,9220	0,0192
zalihe	1,00	4,5551	0,2074
transport	1,58	5,7405	0,1249
čekanje	1,50	6,2583	0,0997
nepotrebna kretanja	1,33	9,6653	0,0216
škart	2,00	4,3706	0,2241
prekomjerna obrada	1,12	0,9274	0,8188
nedovoljno korištenje potencijala radnika	1,50	2,2720	0,5179

Za gubitke u poslovanju poduzeća za koje je provedenim testovima utvrđena statistička znatnost pokazatelja poduzeća – analiza prema veličini poduzeća (tablica 7.6 i 7.7) u nastavku je dan "Boxplot" prikaz (slika 7.1, 7.2, 7.3 i 7.4).


**Slika 7.1.** "Boxplot" – prekomjerna proizvodnja – veličina poduzeća



Slika 7.2. "Boxplot" – zalihe – veličina poduzeća



Slika 7.3. "Boxplot" – transport – veličina poduzeća



Slika 7.4. "Boxplot" – nepotrebna kretanja – veličina poduzeća

Iz analize "Boxplot" prikaza (slika 7.1, 7.2 i 7.3) vidi se da potencijale smanjenja gubitaka u poslovanju poduzeća vezane uz: prekomjernu proizvodnju, zalihe i transport prema veličini poduzeća možemo razvrstati u dvije grupe: mikropoduzeća i ostala poduzeća (mala poduzeća, srednje velika poduzeća i velika poduzeća).

Iz analize "Boxplot" prikaza (slika 7.4) vidi se da se ističe potencijal smanjenja gubitaka u poslovanju poduzeća – nepotrebna kretanja za srednje velika poduzeća. S obzirom na to da je to izoliran slučaj, u daljnjim analizama upotrebljavat će se podjela na: mikropoduzeća i ostala poduzeća.

Prema provedenim testovima zaključuje se da na potencijale smanjenja gubitaka u poslovanju hrvatskih poduzeća statistički znatno utječe pokazatelj poduzeća – veličina poduzeća, a navedeni potencijali mogu se razvrstati u dvije grupe: mikropoduzeća i ostala poduzeća.

7.2.2. Analiza prema djelatnosti poduzeća

Budući da se radi o usporedbi između dva nezavisna uzorka, za statističku obradu prikupljenih podataka prema djelatnosti poduzeća (proizvodna poduzeća i uslužna poduzeća) primijenjen je *Mann-Whitneyev U test*.

Provedenim *Mann-Whitneyevim U testom* (tablica 7.8) vjerojatnost odbacivanja nulte hipoteze " p " veća je od 0,05 za gubitke u poslovanju poduzeća "transport" i "škart" pa je statistički neznatna (na razini znatnosti od 5 %). Za ostale analizirane gubitke u poslovanju poduzeća vjerojatnost odbacivanja nulte hipoteze " p " manja je od 0,05 pa je statistički znatna (na razini znatnosti od 5 %). Prema ovom testu statistički znatan utjecaj ima pokazatelj poduzeća - djelatnost poduzeća na potencijal smanjenja gubitaka u poslovanju hrvatskih poduzeća.

Tablica 7.8. *Mann-Whitneyev U test* – potencijal smanjenja gubitaka – analiza prema djelatnosti poduzeća

Gubitak u poslovanju poduzeća	suma rangova uslužna	suma rangova proiz.	U	p	broj uslužnih	broj proiz.
prekomjerna proizvodnja	15395,0	20920,0	7010,0	0,0015	129	140
zalihe	14258,0	18382,0	6632,0	0,0116	123	132
transport	15563,0	19417,0	7562,0	0,0678	126	138
čekanje	15227,5	20283,5	6842,5	0,0014	129	137
nepotrebna kretanja	12272,0	17131,0	5831,0	0,0073	113	129
škart	11976,5	16226,5	6090,5	0,0959	108	129
prekomjerna obrada	12279,5	16161,5	5724,5	0,0113	114	124
nedovoljno korištenje potencijala radnika	13394,5	18231,5	6013,5	0,0012	121	130

7.2.3. Analiza prema radnom mjestu sudionika istraživanja

Kod analize utjecaja pokazatelja poduzeća - radno mjesto sudionika istraživanja na potencijal smanjenja gubitaka u poslovanju poduzeća, budući da se radi o usporedbi četiri nezavisna uzorka (vrhovni menadžment, srednji menadžment, prva razina menadžmenta i operativna razina), primijenjeni su *Kruskal-Wallisova analiza varijance rangova (H - test)* i *Medijan test*.

Na temelju provedenog *Kruskal-Wallisova testa* (tablica 7.9) vidi se da je vjerojatnost odbacivanja nulte hipoteze " p " veća od 0,05 pa je statistički neznatna (na razini znatnosti od 5 %) za analizirane potencijale smanjenja gubitaka u poslovanju poduzeća.

Iz prikazanih rezultata *Medijan testa* (tablica 7.10) vidi se da je vjerojatnost odbacivanja nulte hipoteze " p " manja od 0,05 pa je statistički znatna (na razini znatnosti od 5 %) za potencijal smanjenja gubitaka u poslovanju poduzeća "prekomjerna proizvodnja". Za navedeni potencijal smanjenja gubitaka u poslovanju poduzeća na slici 7.5 dan je "Boxplot" prikaz.

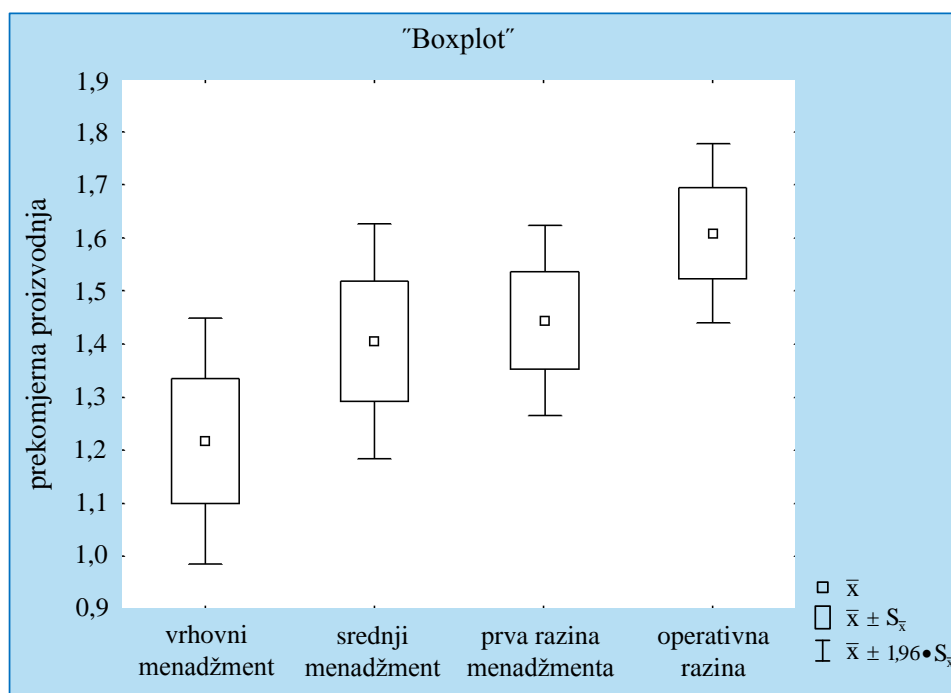
Tablica 7.9. *Kruskal-Wallisov test* – potencijal smanjenja gubitaka – analiza prema radnom mjestu sudionika istraživanja

Gubitak u poslovanju poduzeća	broj uzoraka	<i>H - test</i>	<i>p</i>
prekomjerna proizvodnja	269	7,3717	0,0610
zalihe	255	3,7404	0,2909
transport	264	2,3346	0,5059
čekanje	266	3,1845	0,3640
nepotrebna kretanja	242	4,0965	0,2512
škart	237	2,9061	0,4063
prekomjerna obrada	238	1,4414	0,6958
nedovoljno korištenje potencijala radnika	251	5,4331	0,1427

Tablica 7.10. *Medijan test* – potencijal smanjenja gubitaka – analiza prema radnom mjestu sudionika istraživanja

Gubitak u poslovanju poduzeća	ukupni medijan	χ^2	p
prekomjerna proizvodnja	1,50	7,8725	0,0487
zalihe	1,00	1,1871	0,7561
transport	1,58	1,1941	0,7544
čekanje	1,50	1,5582	0,6689
nepotrebna kretanja	1,33	2,8019	0,4232
škart	2,00	2,4815	0,4786
prekomjerna obrada	1,12	2,5639	0,4639
nedovoljno korištenje potencijala radnika	1,50	7,0363	0,0708

Iz "Boxplot" prikaza na slici 7.5 vidi se da prema sudionicima istraživanja iz vrhovnog menadžmenta poduzeća postoji manji potencijal, a prema sudionicima istraživanja iz operativne razine poduzeća postoji nešto veći potencijal za smanjenje gubitka u poslovanju poduzeća "prekomjerna proizvodnja" u odnosu na potencijal smanjenja tog gubitka prema sudionicima istraživanja iz srednjeg menadžmenta poduzeća i prve razine menadžmenta poduzeća.

**Slika 7.5.** "Boxplot" – prekomjerna proizvodnja – radno mjesto sudionika istraživanja

Medijan test (tablica 7.10) pokazao je da statistički znatan utjecaj ima pokazatelj poduzeća – radno mjesto sudionika istraživanja na jedan potencijal (od ukupno njih osam) smanjenja gubitaka u poslovanju hrvatskih poduzeća "prekomjerna proizvodnja". Ukupno gledajući, iz ostalih rezultata provedenih testova (tablica 7.9) i "Boxplot" prikaza (slika 7.5) može se reći da su razlike u odgovorima sudionika istraživanja vezanim uz potencijal smanjenja gubitaka u poslovanju hrvatskih poduzeća statistički neznatne o radnom mjestu sudionika istraživanja.

8. EVALUACIJA POGODNOSTI PRIMJENE VITKIH ALATA PREMA POKAZATELJIMA PODUZEĆA

Za izradu modela učinkovitoga upravljanja poduzećem koji se temelji na suvremenim alatima vitke i zelene proizvodnje potrebno je poznavati koji od njih imaju najveći utjecaj na smanjenje gubitaka u poslovanju poduzeća.

Prethodno provedenim analizama pokazano je da se odgovori sudionika istraživanja statistički znatno razlikuju za različite djelatnosti poduzeća (proizvodna i uslužna poduzeća) i veličini poduzeća (mikropoduzeća i ostala poduzeća). Za svaku od kombinacija pokazatelja poduzeća:

- proizvodna mikropoduzeća
- proizvodna mala, srednja i velika poduzeća
- uslužna mikropoduzeća
- uslužna mala, srednja i velika poduzeća

izrađena je rang lista vitkih alata radi odabira najpogodnijeg vitkog alata za smanjenje gubitaka u poslovanju poduzeća.

Za izradu navedenih rang listi – evaluaciju pogodnosti primjene vitkih alata, uz podatke o potencijalima smanjenja gubitaka u poslovanju poduzeća (anketno pitanje: 7.) i podataka iz literature, primijenjena je metoda analitičkog hijerarhijskog procesa odlučivanja (e. *Analitic hierarchy process – AHP*).

8.1. Analitički hijerarhijski proces (e. *Analitic Hierarchy Process – AHP*)

Analitički hijerarhijski proces odlučivanja (e. *Analitic Hierarchy Process – AHP*) osmislio je Thomas L. Saaty 1970-ih godina. AHP metoda bazira se na matematici i psihologiji te spada u najpoznatije metode višekriterijskog odlučivanja. Njezina popularnost proizlazi odatle što rješava složene probleme rastavljajući ih na jednostavnije komponente: ciljeve, kriterije i alternative, odnosno rastavlja kompleksni višekriterijski problem na sustavnu hijerarhijsku strukturu. [69, 77]

Prednost je AHP metode što se može upotrijebiti kada su poznati samo međusobni odnosi alternativa prema pojedinim kriterijima (potkriterijima) i međusobna važnost kriterija u odnosu na cilj. Također se može upotrijebiti i onda kada su zadane egzaktne vrijednosti alternativa prema pojedinim kriterijima (potkriterijima) te težina svakog kriterija. [78]

AHP metoda primjenjuje se za odabir prioriteta, odluka ili za ocjenjivanje u raznim područjima (poput: raspodjele resursa, upravljanja kvalitetom) kao i u specifičnim područjima marketinga, energetike, medicine, istraživanja i razvoja i dr. [69, 77, 78]

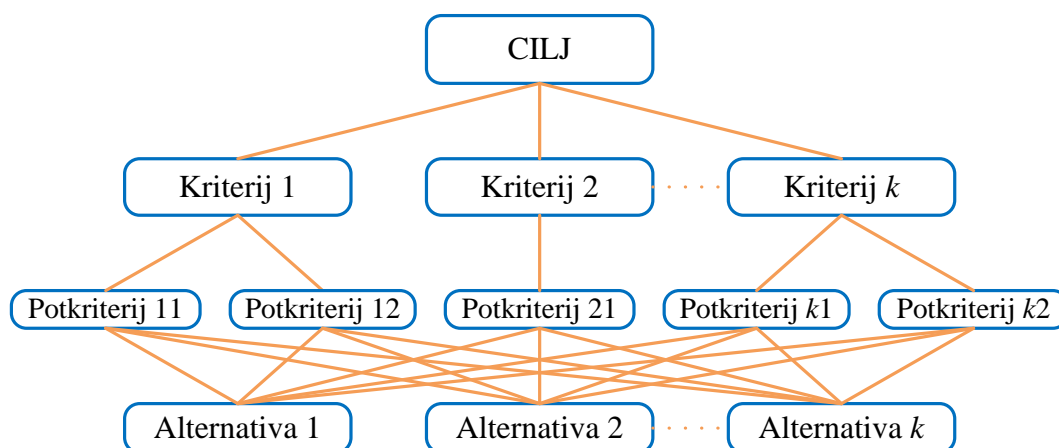
Struktura i način funkcioniranja AHP metode može se prikazati s pomoću četiri osnovna koraka: [77, 78, 79]

1. Definiranje problema i izrada hijerarhijske strukture problema odlučivanja.
2. Na svakoj razini hijerarhijske strukture u parovima međusobno usporediti elemente.
3. Procjenom relativnih važnosti elemenata za odgovarajuću razinu hijerarhijske strukture izračunati lokalne prioritete kriterija, potkriterija i alternativa.
4. Sintetiziranjem lokalnih prioriteta u ukupne prioritete alternativa odrediti konačno rješenje.

Navedeni koraci AHP metode detaljnije su opisani u onome što slijedi.

8.1.1. Izrada hijerarhijske strukture problema odlučivanja

Izrada hijerarhijske strukture problema odlučivanja s ciljem na vrhu, a s kriterijima i potkriterijima na nižim razinama te alternativama na najnižoj hijerarhijskoj razini (slika 8.1).



Slika 8.1. Hijerarhijski prikaz strukturiranja problema

Važno je da su određeni kriteriji koji mogu zadovoljiti cilj, ali pritom kriteriji prve razine najviše utječu na odluku, dok kriteriji druge, treće i nižih razina imaju manji utjecaj na konačnu odluku. [77, 79]

8.1.2. Usporedba elemenata hijerarhijske strukture u parovima

Na svakoj razini hijerarhijske strukture u parovima međusobno se uspoređuju elementi te strukture s pomoću odgovarajuće *Saatyjeve skale* (tablica 8.1).

Tablica 8.1. *Saatyjeva skala* prioriteta [80]

Ocjena prioriteta	Opisna ocjena prioriteta
1	Jednaki prioritet
2	Jednaki do umjereni prioritet
3	Umjereni prioritet
4	Umjereni do jaki prioritet
5	Jaki prioritet
6	Jaki do vrlo jaki prioritet
7	Vrlo jaki prioritet
8	Vrlo jaki do apsolutni prioritet
9	Apsolutni prioritet

Donositelj odluke sustavno ocjenjuje kriterije i potkriterije uspoređujući ih međusobno u parovima s obzirom na njihov utjecaj na element iznad njih u hijerarhiji. [79]

8.1.3. Izračun lokalnih prioriteta kriterija, potkriterija i alternativa

Procjenom relativnih važnosti elemenata za odgovarajuću razinu hijerarhijske strukture problema pomoću odgovarajućeg matematičkog modela izračunavaju se lokalni prioriteti kriterija, potkriterija i alternativa.

Formiraju se matrice usporedbe kojima se definiraju preferencije dobivene usporedbom parova određene razine hijerarhije u odnosu na višu razinu hijerarhije. Kod formiranja matrice

usporedbe potrebno se pridržavati pravila: "Ako se iznos usporedbe nalazi na lijevoj strani *Saatyjeve skale*, u matricu se upisuje isti taj iznos, a ako se iznos usporedbe nalazi na desnoj strani *Saatyjeve skale*, u matricu se upisuje recipročna vrijednost iznosa" [79]. Stupci u matricama normaliziraju se i određuje se vektor težina ili prioriteta kriterija u odnosu na cilj i vektor težina ili prioriteta alternativa po svakom kriteriju. [78]

Za dobivanje vektora prioriteta obično se koristi metoda svojstvenog vektora (e. *Eigenvectors methods*) koju je predložio Saaty. Za izračun vektora prioriteta primjenjuju se i druge metode poput: metoda aditivne normalizacije (e. *Additive Normalization Method*), metoda geometrijske sredine (e. *Geometric Mean Method*) i dr. [81]

8.1.3.1. Metoda svojstvenog vektora (e. *Eigenvectors methods*)

Metoda svojstvenog vektora temeljna je metoda prioriteta i najčešće primjenjivana metoda usporedbe. Ona je izvorna metoda koju Saaty predlaže za dobivanje prioriteta u AHP metodi. Prema Saatyju, glavni svojstveni vektor matrice A može se upotrijebiti kao željeni prioritetni vektor primjenom *Perron – Frobeniusova* teorema. Vektor prioriteta w dobiva se rješavanjem jednadžbe (izraz 8.1): [81]

$$A w = \lambda_{\max} w \quad \lambda_{\max} \geq n \quad (8.1)$$

gdje je: w – vektor prioriteta, λ_{\max} – maksimalna vrijednost matrice A ,

Ako je matrica A konzistentna, tada je $\lambda_{\max} = n$, u protivnom je $\lambda_{\max} > n$.

Nakon što se formira matrica usporedbe koja je dobivena usporedbom parova određene razine hijerarhije u odnosu na višu razinu hijerarhije, postupak izračuna vektora prioriteta prikazan u koracima sljedeći je: [81]

1. Množenje matrice usporedbe
2. Računa se prvi vektor prioriteta (*1. eigenvector*)

Postupak je sljedeći: zbroje se svi elementi pojedinog reda matrice, koji se zatim podijele s ukupnim zbrojem vrijednosti pojedinih redova, čime se dobiva prvi normalizirani prioritetni vektor

3. Ponavlja se korak 1. i 2. sve dotle dok vektor prioriteta nije sličan vrijednosti prethodne iteracije ili je zadovoljen izraz (8.1).

8.1.3.2. Konzistentnost procjena

AHP metoda omogućuje provjeru konzistentnosti procjena donositelja odluke nakon uspoređivanja elemenata hijerarhije. S pomoću indeksa konzistentnosti CI kao mjere konzistentnosti odstupanja n od λ_{\max} može se izračunati omjer konzistentnosti CR . Indeks konzistentnosti CI i omjer konzistentnosti CR definirani su izrazima 8.2 i 8.3: [80, 82]

$$CI = \frac{\lambda_{\max} - n}{n - 1} \quad (8.2)$$

gdje je: CI – indeks konzistentnosti, λ_{\max} – maksimalna vrijednost matrice, a n – broj redova matrice.

$$CR = \frac{CI}{RI} \quad (8.3)$$

gdje je: CR – omjer konzistentnosti, CI – indeks konzistentnosti, a RI – slučajni indeks konzistentnosti

Vrijednosti slučajnog indeksa konzistentnosti RI ovisno o broju redova matrice n navedene su u tablici 8.2.

Tablica 8.2. Vrijednost RI slučajnih indeksa [84]

n	1	2	3	4	5	6	7	8	9	10	11	12
RI	0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49	1,51	1,48

Kada je omjer konzistentnosti $CR \leq 0,10$, procjene relativnih važnosti (težina) kriterija (alternativa) mogu se smatrati prihvatljivima. U protivnom smatramo da procjene nisu bile dovoljno konzistentne da bismo na njima bazirali odluku. [79, 82]

8.1.4. Određivanje konačnog rješenja

Sintetiziranjem lokalnih prioriteta u ukupne prioritete alternativa određuje se konačno rješenje. Kao rezultat potrebno je dobiti ukupnu matricu težine ili prioriteta alternativa u kojoj vektori prioriteta alternativa prema pojedinom kriteriju čine stupce i koja množenjem s vektorom prioriteta kriterija daje ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa. [78]

8.2. Evaluacija pogodnosti primjene vitkih alata za proizvodna mikropoduzeća

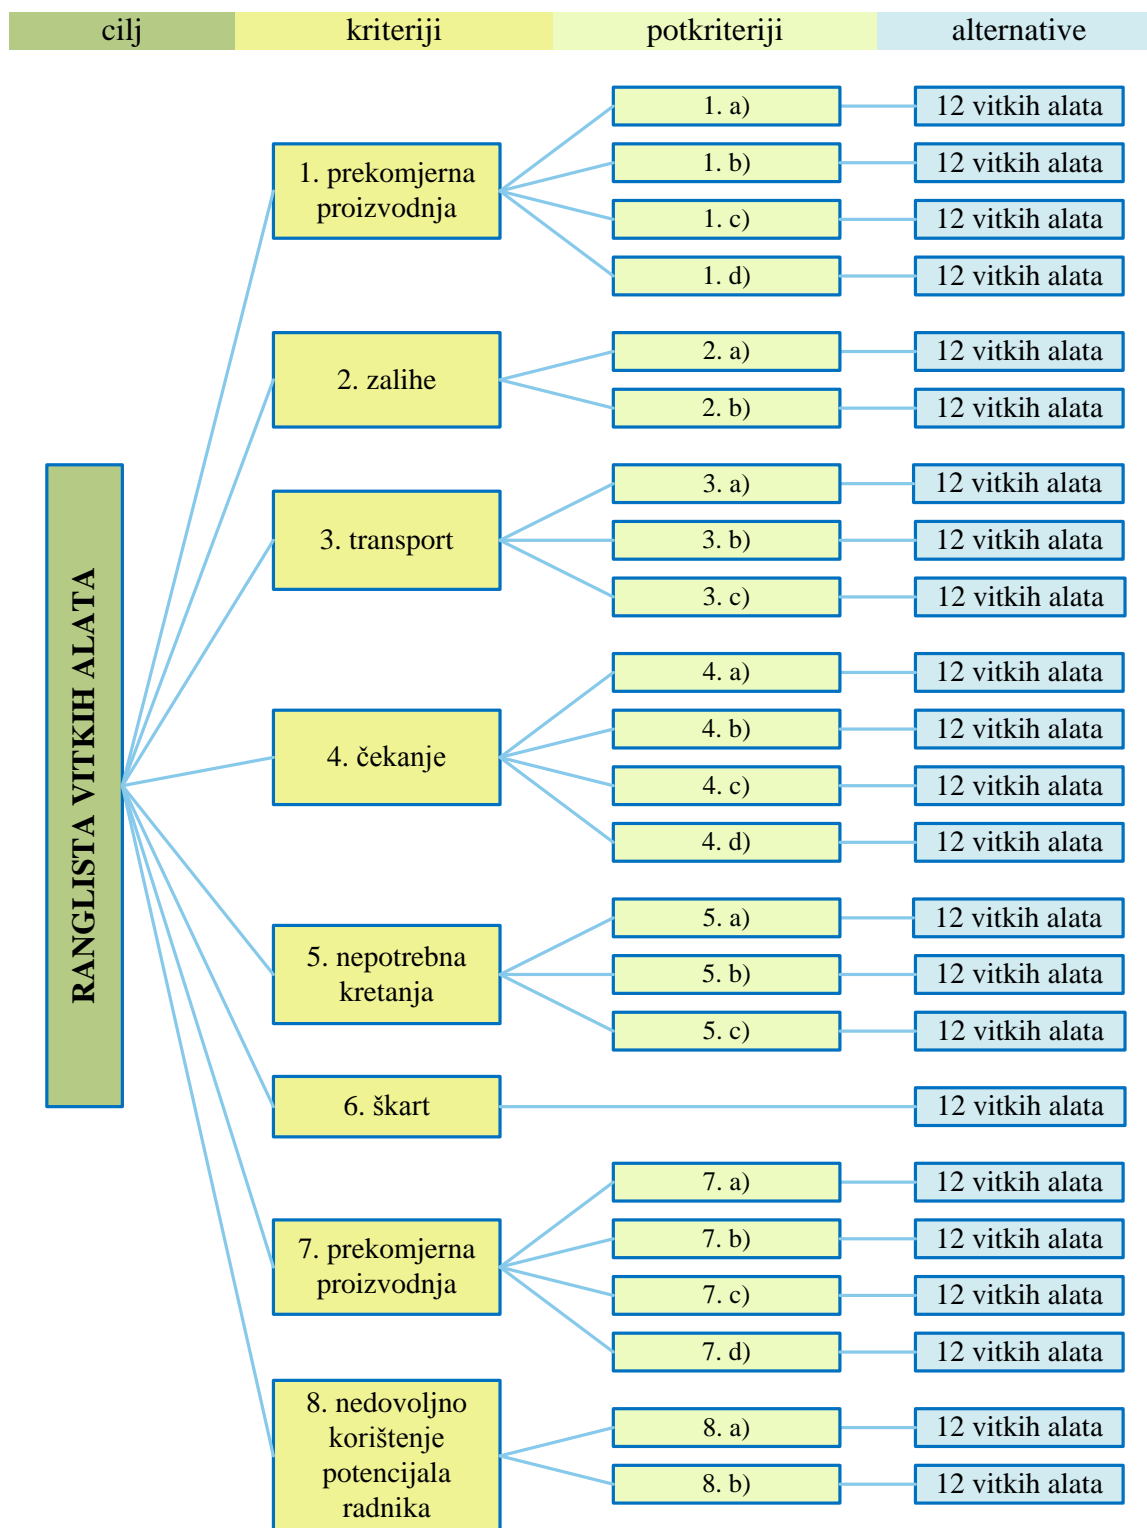
Za izradu rang liste vitkih alata razmatrani su samo odgovori sudionika istraživanja iz proizvodnih mikropoduzeća (24 ankete). Obradom podataka o potencijalima smanjenja gubitaka u poslovanju poduzeća (anketno pitanje: 7.) te podataka iz literature o opisima i primjeni vitkih alata primjenom AHP metode dobivena je rang lista vitkih alata karakteristična za hrvatska proizvodna mikropoduzeća. Postupak izrade rang liste vitkih alata primjenom AHP metode navodi se u nastavku.

8.2.1. Izrada hijerarhijske strukture

Rang lista vitkih alata karakteristična za hrvatska proizvodna mikropoduzeća je cilj pa se nalazi na vrhu hijerarhijske strukture problema koja je prikazana na slici 8.2.

Na slici 8.2 na prvoj razini ispod cilja nalazi se 8 kriterija (prekomjerna proizvodnja, zalihe, transport, čekanje, i dr.), na nižoj razini 23 potkriterija (stvaranje proizvoda/usluga koji se ne mogu plasirati na tržištu, stvaranje dokumentacije koju nitko ne zahtijeva, i dr.). Vezama između kriterija i potkriterija definirano je koji se potkriteriji odnose na koji kriterij.

Na najnižoj razini hijerarhijske strukture nalazi se 12 alternativa – vitkih alata (Kanban, Kaizen, mapiranje toka vrijednosti i dr.).



Slika 8.2. Hijerarhijska struktura problema

Radi preglednosti prikaza potkriteriji i alternative (12 vitkih alata) nisu prikazani na slici 8.2, već se navode u nastavku (tablica 8.3 i 8.4).

Tablica 8.3. Potkriteriji

Potkriteriji
1. a) Stvaranje proizvoda/usluga koji se ne mogu plasirati na tržištu 1. b) Stvaranje dokumentacije koju nitko ne zahtijeva 1. c) Slanje uputa prema previše (premalo) ljudi 1. d) Proizvodnja za "svaki slučaj"
2. a) Visoke zalihe ("zamrznuti kapital" u skladištima) 2. b) Više materijala i informacija nego što je potrebno
3. a) Nepotrebno kretanje materijala (obradaka) između operacija 3. b) Neučinkovito i nepotrebno kretanje informacija 3. c) Neuspješna komunikacija: gubitak podataka, nepouzdanost informacija, i sl.
4. a) Vrijeme čekanja materijala između operacija 4. b) Čekanje radnika na strojevima 4. c) Čekanje na podatke, informacije, odluke, potpis, odobrenje ... 4. d) Čekanje na isporuku (npr. kasni sirovina)
5. a) Loš raspored strojeva – nepotrebno kretanje radnika 5. b) Ljudi se trebaju kretati kako bi došli do informacija 5. c) Ručni rad kako bi se kompenzirali nedostaci u procesu
7. a) Predimenzionirani strojevi 7. b) Kriva ili nedostatna tehnološka oprema 7. c) Previše procesa obrade 7. d) Loš dizajn proizvoda koji zahtijeva previše koraka obrade
8. a) Radnike se ne uključuje u aktivnosti poboljšanja procesa 8. b) Ne uključivanje u Kaizen radionice

Tablica 8.4. Alternative

Alternative – 12 vitkih alata	
- U pravo vrijeme (JIT)	- Kontinuirani tok
- Kanban	- Mapiranje toka vrijednosti
- Standardizirani rad	- 5 S
- Kaizen	- Poka Yoke
- Brza zamjena alata (SMED)	- Cjelovito produktivno održavanje (TPM)
- Taktno vrijeme	- Jidoka


8.2.2. Usporedba elemenata hijerarhijske strukture u parovima

8.2.2.1. Usporedba kriterija (potkriterija) u parovima

Provedenom anketom (anketno pitanje: 7.) dobiveni su potencijali smanjenja gubitaka u poslovanju hrvatskih poduzeća (rangiranjem 0 = nema potencijala,..., 3 = veliki potencijal), pa zato nije rađena usporedba kriterija (potkriterija) u parovima prema *Saatyjevoj skali*.

Iz podataka prikupljenih anketom za proizvodna mikropoduzeća prema pojedinim kriterijima (prekomjerna proizvodnja, zalihe, transport i dr.) izračunati su prosječni potencijali smanjenja gubitaka u poslovanju poduzeća. Isti postupak proveden je i prema pojedinim potkriterijima (1. a) Stvaranje proizvoda/usluga koji se ne mogu plasirati na tržištu, 1. b) Stvaranje dokumentacije koju nitko ne zahtjeva, i dr.).

Na slici 8.3 prikazani su prosječni potencijali smanjenja gubitaka u poslovanju poduzeća prema kriterijima i potkriterijima. Vrijednosti u zagradama odgovaraju broju uzorka razmatranog kriterija (potkriterija). Kao što se vidi, cilj je na slici označen zelenom bojom, kriteriji i potkriteriji žutom, a alternative plavom bojom.



Slika 8.3. AHP rang lista vitkih alata – proizvodna mikropoduzeća – prosječni potencijali po kriterijima i potkriterijima

8.2.2.2. Usporedba alternativa (vitkih alata) u parovima

Sukladno klasičnoj AHP metodi provedena je usporedba alternativa prema *Saatyjevoj skali* prema svim potkriterijima i jednom kriteriju (6. škart) – budući da nema potkriterija. Usporedba u parovima provedena je prema postupku opisanom u poglavlju 8.1.2. Prikaz matrice usporedbe za potkriterij 1. d) Proizvodnja za "svaki slučaj" naveden je u tablici 8.5. Matrice usporedbe za sve ostale potkriterije i kriterij (6. škart) nalaze se u Prilogu rada.

Tablica 8.5. Matrica usporedbe alternativa prema potkriteriju 1. d)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Jidoka	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
JIT	5	5	1	5	1/3	5	5	5	1/2	5	1/2	5
Kaizen	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Kanban	8	8	3	8	1	8	8	8	2	8	3	8
Kont. tok	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Map. toka vr.	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Poka Yoke	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
SMED	7	7	2	7	1/2	7	7	7	1	7	2	7
Standard. rad	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Taktno vr.	6	6	2	6	1/3	6	6	6	1/2	6	1	6
TPM	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1

8.2.3. Izračun prioriteta

8.2.3.1. Izračun prioriteta kriterija i potkriterija

Postupak izračuna lokalnih prioriteta kriterija i potkriterija na osnovi prosječnih vrijednosti potencijala smanjenja gubitaka u poslovanju poduzeća prikazanih na slici 8.3 je sljedeći:

- Prvo se za kriterije izračunaju udjeli vrijednosti potencijala smanjenja gubitaka u poslovanju poduzeća od ukupnog zbroja, koji se zatim normaliziraju pa se dobiju lokalni prioriteti (e. *local priorities*) kriterija (slika 8.4). Postupak izračuna lokalnih prioriteta kriterija prikazan je u tablici 8.6.

Tablica 8.6. Izračun lokalnih prioriteta kriterija

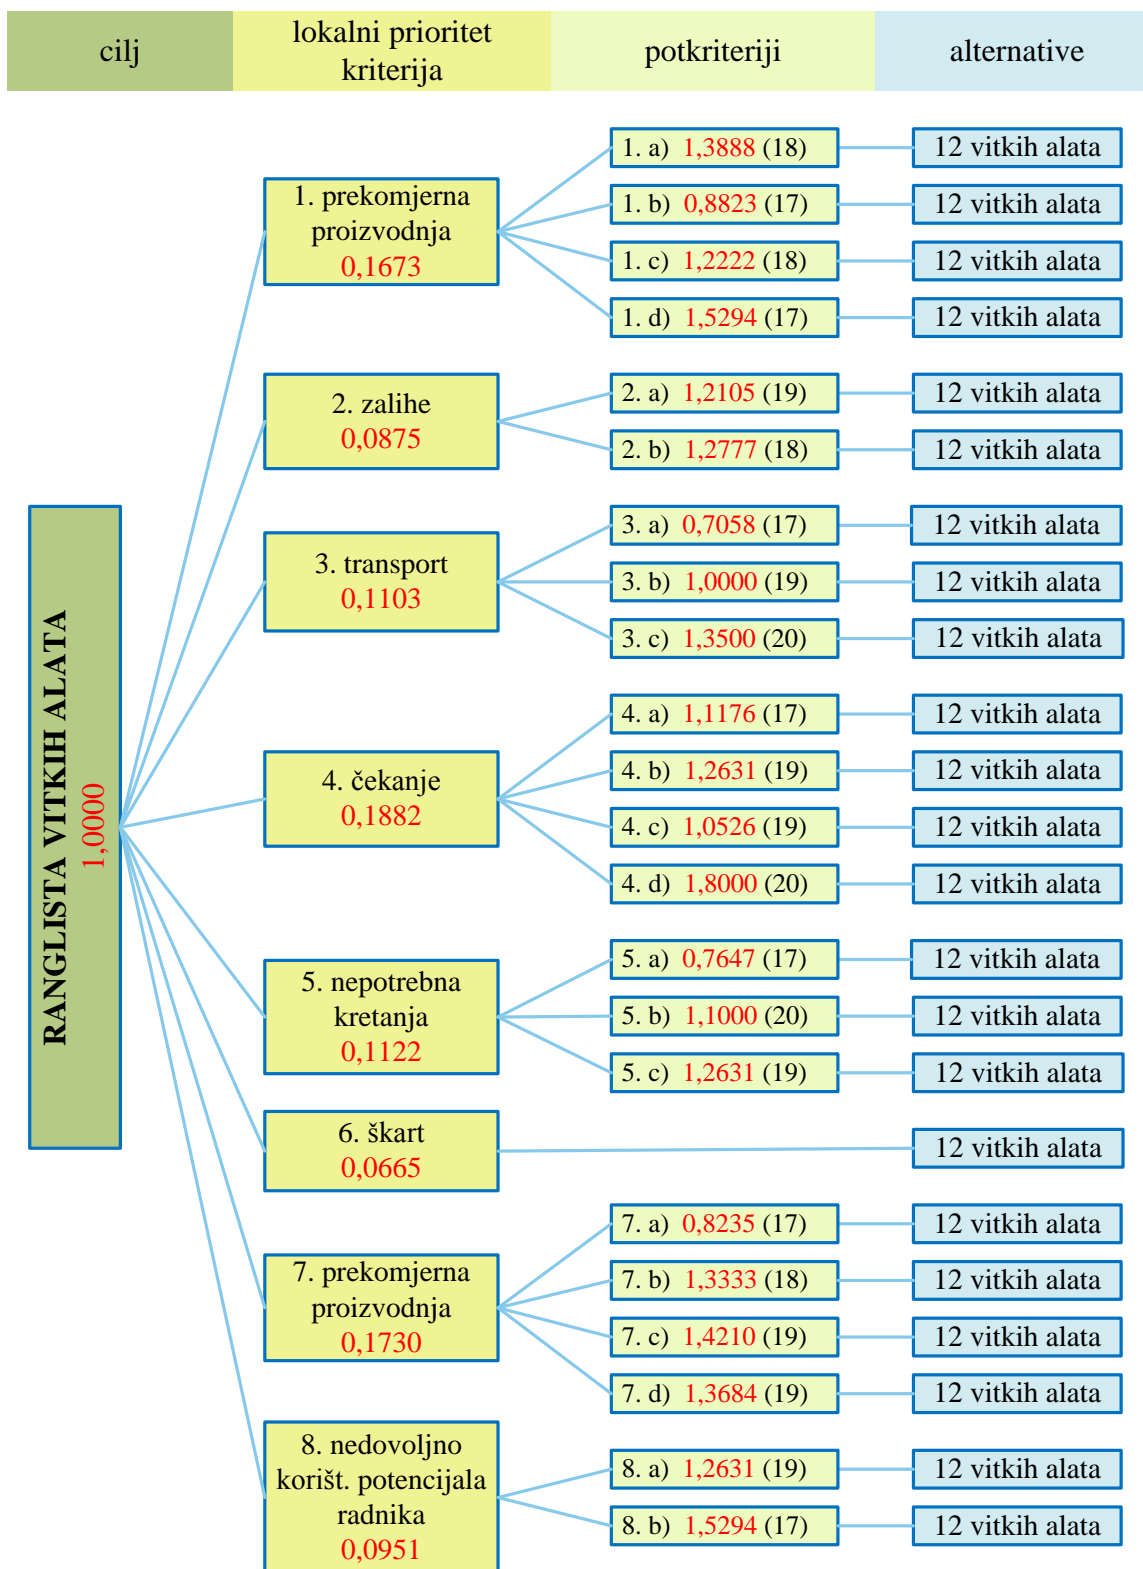
kriterij		lokalni prioritet
prekomjerna proizvodnja	$1,2571 \cdot 70 / 426 = 0,2066$	0,1673
zalihe	$1,2432 \cdot 37 / 426 = 0,1080$	0,0875
transport	$1,0357 \cdot 56 / 426 = 0,1361$	0,1103
čekanje	$1,3200 \cdot 75 / 426 = 0,2342$	0,1882
nepotrebna kretanja	$1,0535 \cdot 56 / 426 = 0,1385$	0,1122
škart	$1,5217 \cdot 23 / 426 = 0,0822$	0,0665
prekomjerna obrada	$1,2465 \cdot 73 / 426 = 0,2136$	0,1730
nedovoljno. kor. pot. radnika	$1,3888 \cdot 36 / 426 = 0,1174$	0,0951
1,2346		1,0001

- Isti postupak provede se i za potkriterije (slika 8.5). Postupak izračuna lokalnog prioriteta potkriterija za kriterij prekomjerna proizvodnja prikazan je u tablici 8.7.

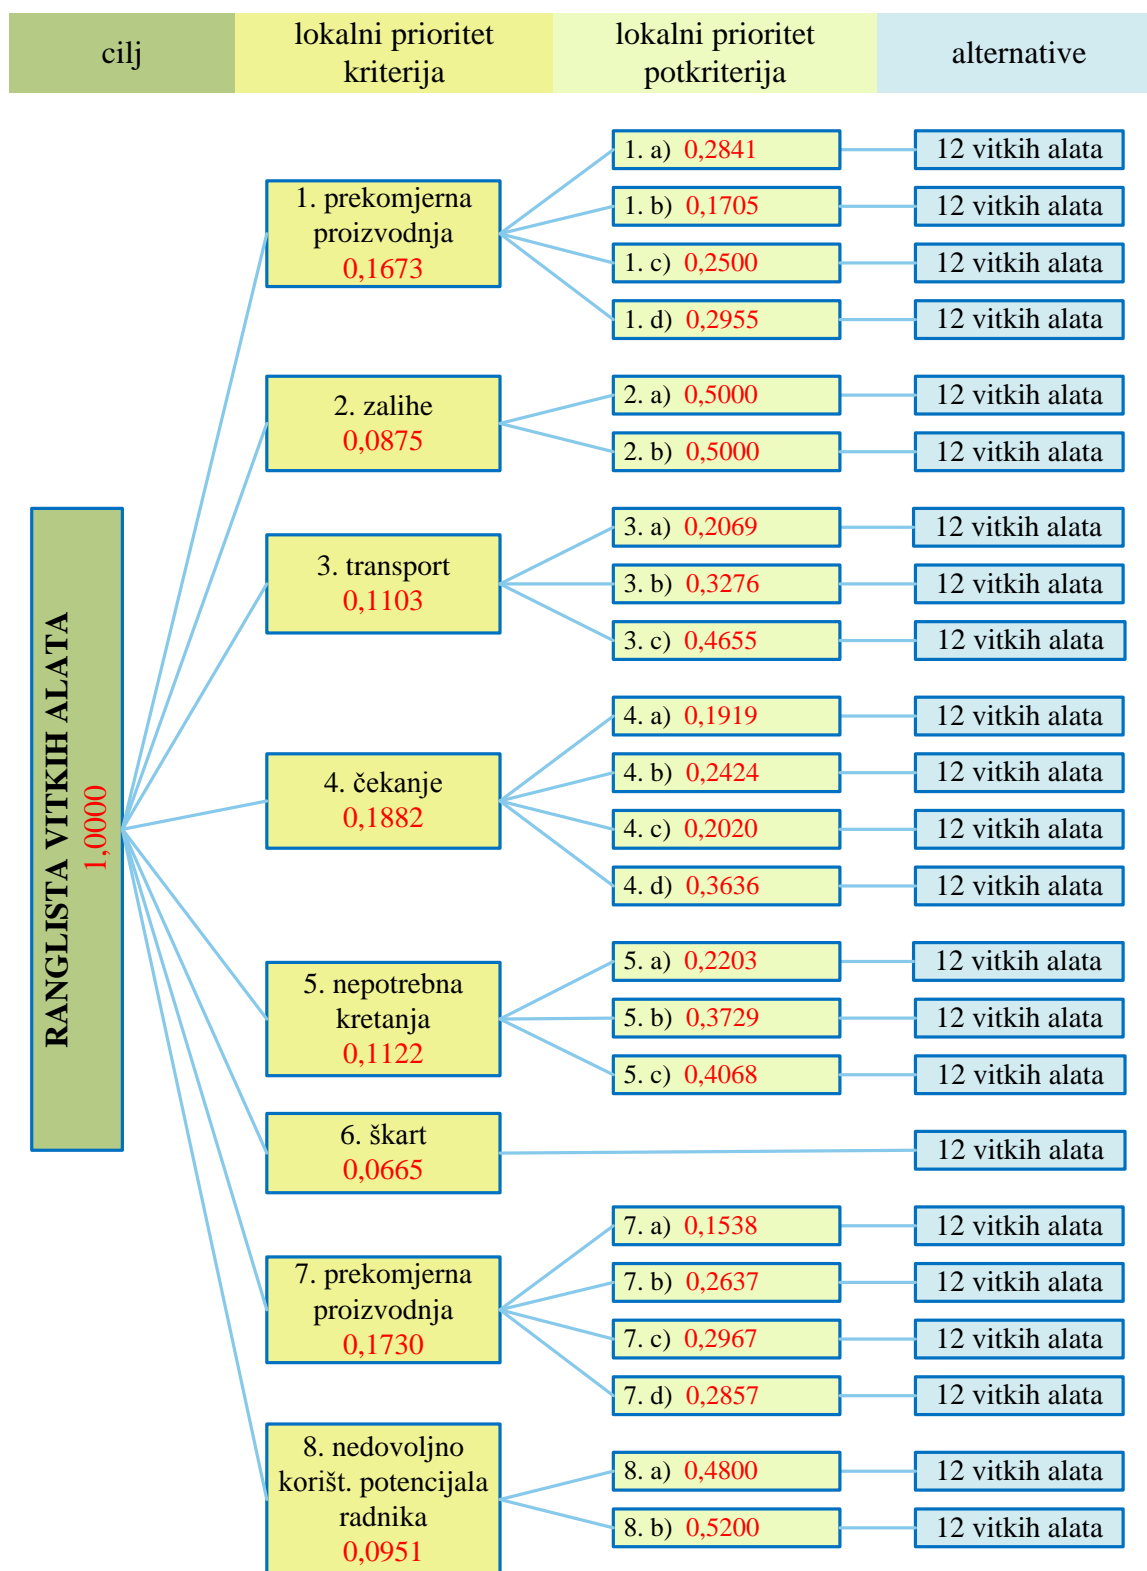
Tablica 8.7. Izračun lokalnog prioriteta potkriterija

kriterij	potkriteriji	lokalni prioritet
prekomjerna proizvodnja	$1,3888 \cdot 18 / 70 = 0,3571$	0,2841
	$0,8823 \cdot 17 / 70 = 0,2143$	0,1705
	$1,2222 \cdot 18 / 70 = 0,3143$	0,2500
	$1,5294 \cdot 17 / 70 = 0,3714$	0,2955
1,2571		1,0001

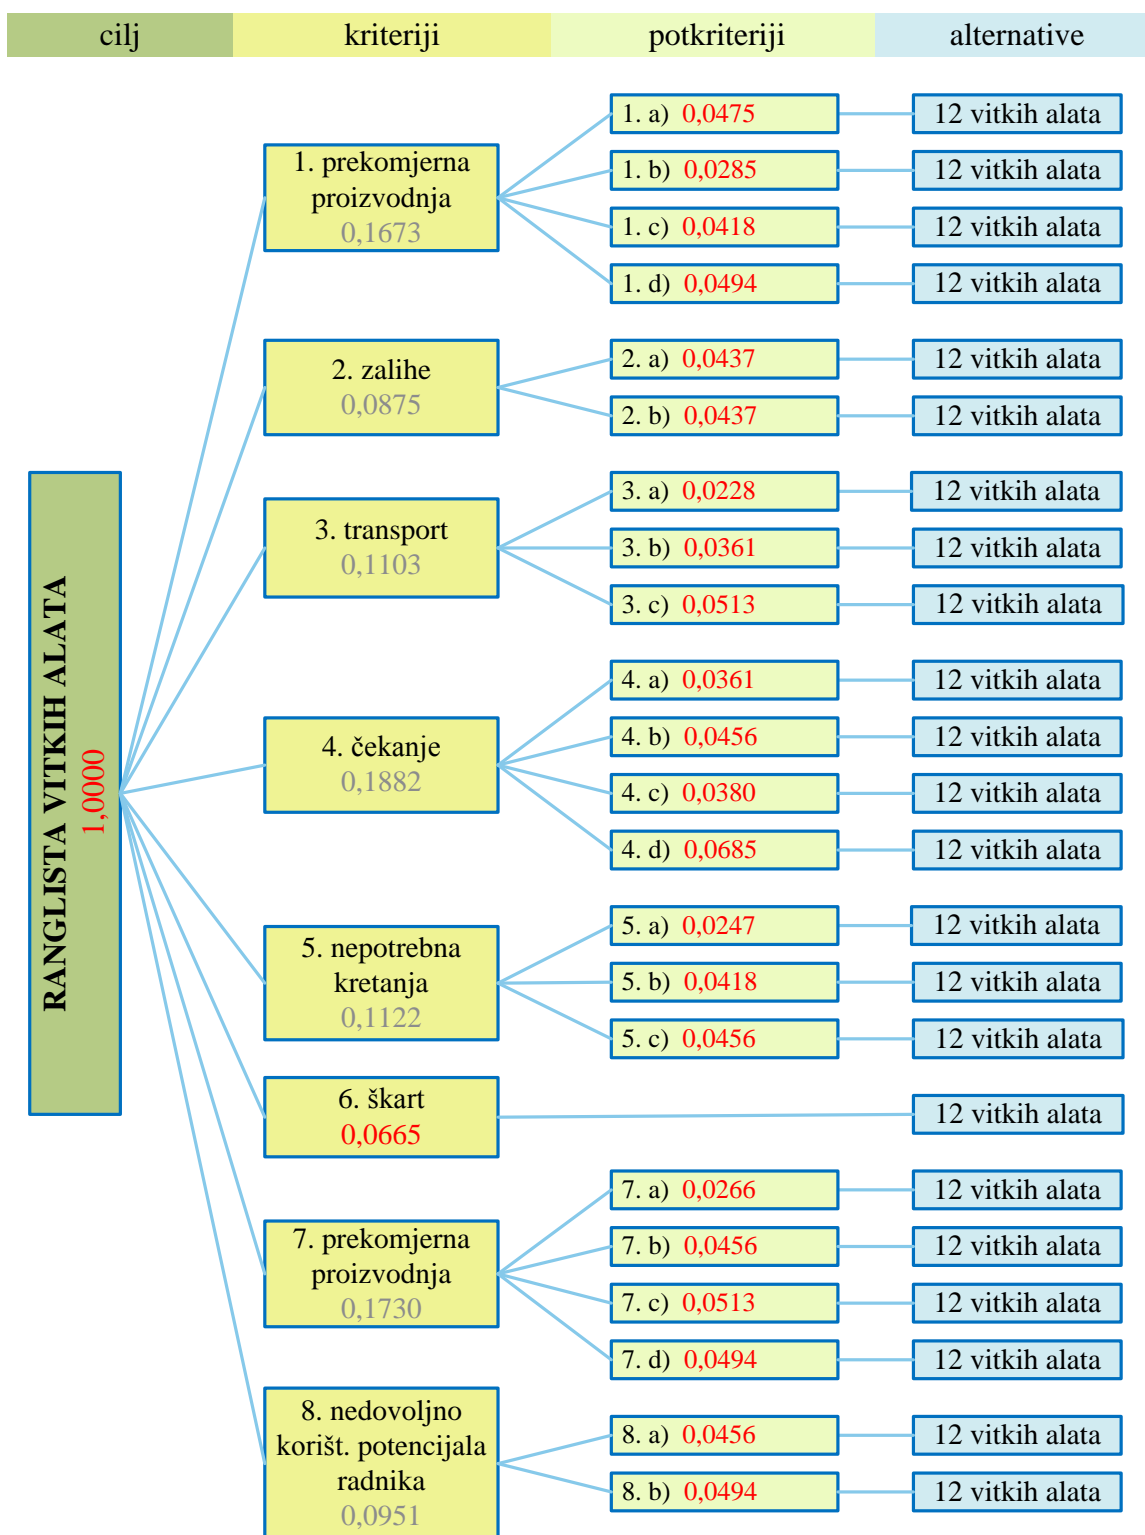
- Globalni prioritet (e. *global priorities*) kriterija i potkriterija izračunat je množenjem lokalnih prioriteta kriterija i pripadajućih potkriterija (slika 8.6).



Slika 8.4. AHP rang lista vitkih alata – proizvodna mikropoduzeća – lokalni prioritet kriterija i prosječni potencijali prema potkriterijima



Slika 8.5. AHP rang lista vitkih alata – proizvodna mikropoduzeća – lokalni prioriteti kriterija i potkriterija



Slika 8.6. AHP rang lista vitkih alata – proizvodna mikropoduzeća – globalni prioritet kriterija i potkriterija

Prethodno opisanim postupkom dobiven je normaliziran globalni vektor prioriteta kriterija i potkriterija za proizvodna mikropoduzeća (izraz 8.4).

$$\begin{array}{ll}
 1. a) & 0,0475 \\
 1. b) & 0,0285 \\
 1. c) & 0,0418 \\
 1. d) & 0,0494 \\
 2. a) & 0,0437 \\
 2. b) & 0,0437 \\
 3. a) & 0,0228 \\
 3. b) & 0,0361 \\
 3. c) & 0,0513 \\
 4. a) & 0,0361 \\
 4. b) & 0,0456 \\
 4. c) & 0,0380 \\
 4. d) & 0,0685 \\
 5. a) & 0,0247 \\
 5. b) & 0,0418 \\
 5. c) & 0,0456 \\
 6. a) & 0,0665 \\
 7. a) & 0,0266 \\
 7. b) & 0,0456 \\
 7. c) & 0,0513 \\
 7. d) & 0,0494 \\
 8. a) & 0,0456 \\
 8. b) & 0,0494
 \end{array} \quad (8.4)$$

Provjeru konzistentnosti dobivenog globalnog vektora prioriteta kriterija i potkriterija (izraz 8.4) nije potrebno raditi budući da je izračunat na osnovu anketom prikupljenih podataka.

8.2.3.2. Izračun prioriteta alternativa

Prema postupku opisanom u poglavlju 8.1.3.1 izračunati su prioriteti alternativa po kriterijima (potkriterijima). Budući da su rađene matrice usporedbe prema *Saatyjevoj skali*, za svaki izračunati prioritet alternativa provjerena je njegova konzistentnost prema postupku opisanom u poglavlju 8.1.3.2. U tablici 8.8 uz izračunati prioritet alternativa prikazan je i indeks konzistentnosti *CI* i omjer konzistentnosti *CR*.

Tablica 8.8. Prioriteti alternativa prema kriterijima

Alternative	1. a)	1. b)	1. c)	1. d)	2. a)	2. b)
5 S	0,0455	0,0452	0,0455	0,0283	0,0500	0,0324
Jidoka	0,0455	0,0452	0,0455	0,0283	0,0500	0,0324
JIT	0,2727	0,0452	0,0455	0,1266	0,4500	0,3004
Kaizen	0,0455	0,2203	0,0455	0,0283	0,0500	0,0324
Kanban	0,2727	0,0452	0,0455	0,2778	0,0500	0,2301
Kontinuirani tok	0,0455	0,0452	0,2727	0,0283	0,0500	0,1775
Map. toka vrijed.	0,0455	0,0452	0,0455	0,0283	0,0500	0,0324
Poka Yoke	0,0455	0,0452	0,0455	0,0283	0,0500	0,0324
SMED	0,0455	0,0452	0,0455	0,2068	0,0500	0,0324
Standard. rad	0,0455	0,3275	0,2727	0,0283	0,0500	0,0324
Taktno vrijeme	0,0455	0,0452	0,0455	0,1624	0,0500	0,0324
TPM	0,0455	0,0452	0,0455	0,0283	0,0500	0,0324
CI	$3,03 \cdot 10^{-10}$	0,0008	$3,03 \cdot 10^{-6}$	0,0113	$8,33 \cdot 10^{-7}$	0,0074
CR	$2,05 \cdot 10^{-10}$	0,0005	$2,05 \cdot 10^{-6}$	0,0076	$5,63 \cdot 10^{-7}$	0,0050

Tablica 8.8. Prioriteti alternativa prema kriterijima od 3. a) do 4. c) - nastavak

Alternative	3. a)	3. b)	3. c)	4. a)	4. b)	4. c)
5 S	0,0500	0,0417	0,0473	0,0455	0,0556	0,1134
Jidoka	0,0500	0,0417	0,0473	0,0455	0,0556	0,0382
JIT	0,0500	0,0417	0,2989	0,0455	0,0556	0,0382
Kaizen	0,0500	0,0417	0,0473	0,0455	0,0556	0,2223
Kanban	0,0500	0,0417	0,0473	0,0455	0,0556	0,0382
Kontinuirani tok	0,0500	0,2917	0,0473	0,4091	0,3889	0,0382
Map. toka vrijed.	0,4500	0,2917	0,0473	0,0455	0,0556	0,0382
Poka Yoke	0,0500	0,0417	0,0473	0,0455	0,0556	0,0382
SMED	0,0500	0,0417	0,0473	0,0455	0,0556	0,0382
Standard. rad	0,0500	0,0417	0,2282	0,0455	0,0556	0,3208
Taktno vrijeme	0,0500	0,0417	0,0473	0,1364	0,0556	0,0382
TPM	0,0500	0,0417	0,0473	0,0455	0,0556	0,0382
CI	$8,33 \cdot 10^{-7}$	$1,52 \cdot 10^{-6}$	0,0016	$1,59 \cdot 10^{-10}$	$8,33 \cdot 10^{-11}$	0,0010
CR	$5,63 \cdot 10^{-7}$	$1,02 \cdot 10^{-6}$	0,0011	$1,07 \cdot 10^{-10}$	$5,63 \cdot 10^{-11}$	0,0007

Tablica 8.8. Prioriteti alternativa prema kriterijima od 4. d) do 7. a) - nastavak

Alternative	4. d)	5. a)	5. b)	5. c)	6. a)	7. a)
5 S	0,0556	0,0500	0,4500	0,0556	0,0958	0,0769
Jidoka	0,0556	0,0500	0,0500	0,0556	0,2603	0,0769
JIT	0,3889	0,0500	0,0500	0,0556	0,0246	0,0769
Kaizen	0,0556	0,0500	0,0500	0,0556	0,0246	0,1538
Kanban	0,0556	0,0500	0,0500	0,0556	0,0246	0,0769
Kontinuirani tok	0,0556	0,0500	0,0500	0,0556	0,0246	0,0769
Map. toka vrijed.	0,0556	0,4500	0,0500	0,0556	0,0246	0,0769
Poka Yoke	0,0556	0,0500	0,0500	0,0556	0,1881	0,0769
SMED	0,0556	0,0500	0,0500	0,0556	0,0246	0,0769
Standard. rad	0,0556	0,0500	0,0500	0,0556	0,0958	0,0769
Taktno vrijeme	0,0556	0,0500	0,0500	0,0556	0,0246	0,0769
TPM	0,0556	0,0500	0,0500	0,3889	0,1881	0,0769
CI	$8,33 \cdot 10^{-11}$	$8,33 \cdot 10^{-11}$	$8,33 \cdot 10^{-11}$	$8,33 \cdot 10^{-11}$	0,0039	$1,61 \cdot 10^{-16}$
CR	$5,63 \cdot 10^{-11}$	$5,63 \cdot 10^{-11}$	$5,63 \cdot 10^{-11}$	$5,63 \cdot 10^{-11}$	0,0026	$1,09 \cdot 10^{-16}$

Tablica 8.8. Prioriteti alternativa prema kriterijima od 7. b) do 8. b) - nastavak

Alternative	7. b)	7. c)	7. d)	8. a)	8. b)
5 S	0,0526	0,0435	0,0556	0,0625	0,0588
Jidoka	0,0526	0,0435	0,0556	0,0625	0,0588
JIT	0,0526	0,0435	0,0556	0,0625	0,0588
Kaizen	0,0526	0,1739	0,3889	0,3125	0,3529
Kanban	0,0526	0,0435	0,0556	0,0625	0,0588
Kontinuirani tok	0,0526	0,0435	0,0556	0,0625	0,0588
Map. toka vrijed.	0,0526	0,3913	0,0556	0,0625	0,0588
Poka Yoke	0,0526	0,0435	0,0556	0,0625	0,0588
SMED	0,0526	0,0435	0,0556	0,0625	0,0588
Standard. rad	0,0526	0,0435	0,0556	0,0625	0,0588
Taktno vrijeme	0,0526	0,0435	0,0556	0,0625	0,0588
TPM	0,4211	0,0435	0,0556	0,0625	0,0588
CI	$1,61 \cdot 10^{-16}$	$8,33 \cdot 10^{-11}$	$8,33 \cdot 10^{-11}$	$9,69 \cdot 10^{-16}$	$1,67 \cdot 10^{-10}$
CR	$1,09 \cdot 10^{-16}$	$5,63 \cdot 10^{-11}$	$5,63 \cdot 10^{-11}$	$6,55 \cdot 10^{-16}$	$1,13 \cdot 10^{-10}$


Na osnovi izračunatih indeksa konzistentnosti *CI* i omjera konzistentnosti *CR* može se zaključiti da su procjene relativnih važnosti alternativa prihvatljive, odnosno konzistentne.

8.2.4. Određivanje konačnog rješenja

Sintetiziranjem lokalnih prioriteta u ukupne prioritete alternativa određuje se konačno rješenje. Množenjem ukupne matrice prioriteta alternativa, u kojoj vektori prioriteta alternativa prema pojedinom kriteriju čine stupce, s vektorom prioriteta kriterija (potkriterija) dobiven je ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata. Navedeni postupak prikazan je izrazom 8.5.

$$\begin{array}{c}
 \text{Vektor prioriteta} \\
 \text{kriterija (potkriterija)}
 \end{array}
 \begin{array}{c}
 \left[\begin{array}{c}
 0,0475 \\
 0,0285 \\
 0,0418 \\
 0,0494 \\
 0,0437 \\
 0,0437 \\
 0,0228 \\
 0,0361 \\
 0,0513 \\
 0,0361 \\
 0,0456 \\
 0,0380 \\
 0,0685 \\
 0,0247 \\
 0,0418 \\
 0,0456 \\
 0,0665 \\
 0,0266 \\
 0,0456 \\
 0,0513 \\
 0,0494 \\
 0,0456 \\
 0,0494
 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \begin{array}{cccc}
 & 1. a) & 1. b) & \dots & 8. b)
 \end{array} \\
 \begin{array}{c}
 \left[\begin{array}{cccc}
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,2727 & 0,0452 & & 0,0588 \\
 0,0455 & 0,2203 & & 0,3529 \\
 0,2727 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & \dots & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,3275 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588
 \end{array} \right]
 \end{array}
 \end{array}
 \cdot
 \begin{array}{c}
 \left[\begin{array}{c}
 0,0719 \\
 0,0632 \\
 \mathbf{0,1282} \\
 0,1107 \\
 0,0793 \\
 0,1008 \\
 0,0934 \\
 0,0584 \\
 0,0564 \\
 0,0899 \\
 0,0575 \\
 0,0904
 \end{array} \right]
 \end{array}
 \quad (8.5)$$

Na osnovi ukupnog vektora prioriteta alternativa u odnosu na cilj na slici 8.7 prikazan je *Pareto dijagram* vitkih alata za smanjenje gubitaka u poslovanju hrvatskih proizvodnih mikropoduzeća.



Slika 8.7. Pareto dijagram vitkih alata za proizvodna mikropoduzeća

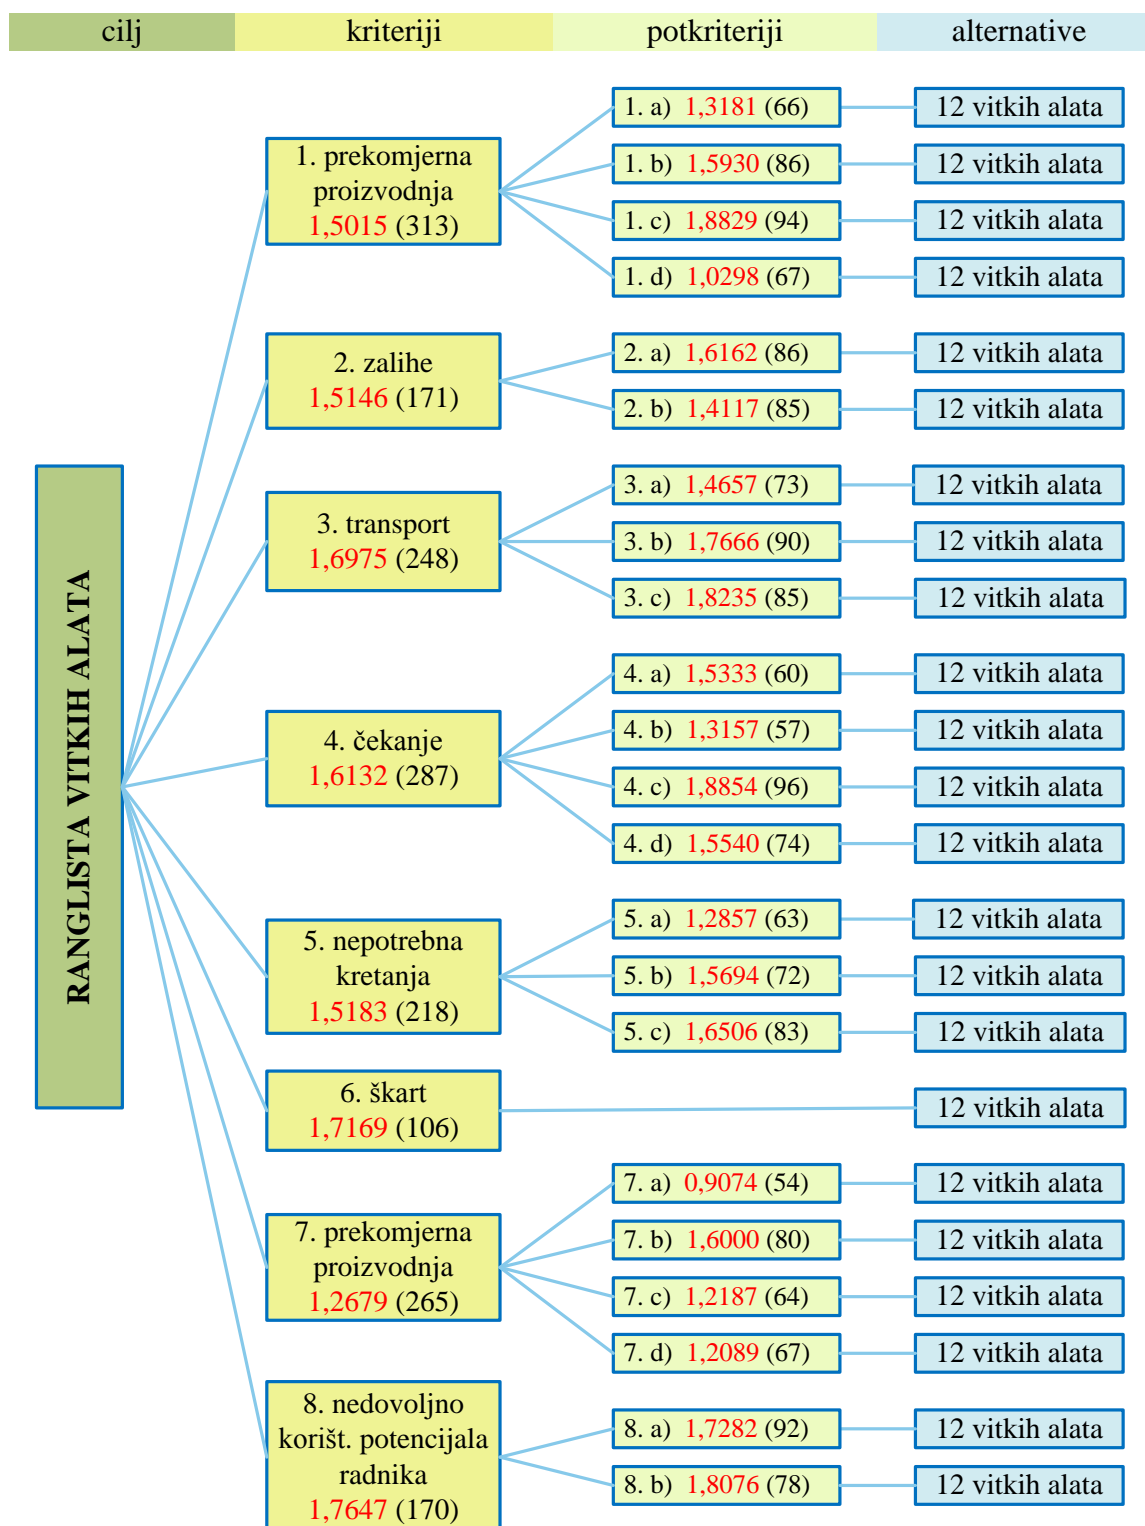
Provedenim istraživanjem zaključeno je da je najpogodniji vitki alat za smanjenje gubitaka u poslovanju hrvatskih proizvodnih mikropoduzeća "U-pravo-vrijeme" – JIT. Zatim slijede Kaizen, kontinuirani tok, mapiranje toka vrijednosti, i dr. Prema istraživanju najmanji utjecaj na smanjenje gubitaka u poslovanju hrvatskih proizvodnih mikropoduzeća ima vitki alat brza zamjena alata – SMED.

8.3. Evaluacija pogodnosti primjene vitkih alata za proizvodna mala, srednje velika i velika poduzeća

Kod evaluacije pogodnosti primjene vitkih alata razmatrani su samo odgovori sudionika istraživanja iz proizvodnih malih, srednje velikih i velikih poduzeća (120 anketa). Postupak evaluacije pogodnosti primjene vitkih alata isti je kao i za proizvodna mikropoduzeća koji je opisan u poglavlju 8.2. Zato je u nastavku naveden skraćeni prikaz postupka:

- hijerarhijska struktura problema – prosječni potencijali prema kriterijima i potkriterijima (slika 8.8)
- izračun prioriteta – normaliziran globalni vektor prioriteta kriterija i potkriterija (izraz 8.6)
- konačno rješenje – ukupni vektor prioriteta alternativa u odnosu na cilj (izraz 8.7) te Pareto dijagram (slika 8.9).

8.3.1. Hijerarhijska struktura problema



Slika 8.8. AHP rang lista vitkih alata – proizvodna mala, srednje velika i velika poduzeća – prosječni potencijali prema kriterijima i potkriterijima

Slikom 8.8 prikazana je hijerarhijska struktura problema zajedno s prosječnim potencijalima prema kriterijima i potkriterijima. Radi preglednosti prikaza potkriteriji i alternative (12 vitkih alata) nisu prikazani na slici, nego su navedeni u tablici 8.3 i 8.4 u poglavlju 8.2.1.

8.3.2. Izračun prioriteta

Prema opisanom postupku izračuna prioriteta kriterija i potkriterija za proizvodna mikropoduzeća u poglavlju 8.2.3.1 izračunat je normaliziran globalni vektor prioriteta kriterija i potkriterija za proizvodna mala, srednja i velika poduzeća (izraz 8.6).

$$\begin{array}{l}
 1. \text{ a)} \\
 1. \text{ b)} \\
 1. \text{ c)} \\
 1. \text{ d)} \\
 2. \text{ a)} \\
 2. \text{ b)} \\
 3. \text{ a)} \\
 3. \text{ b)} \\
 3. \text{ c)} \\
 4. \text{ a)} \\
 4. \text{ b)} \\
 4. \text{ c)} \\
 4. \text{ d)} \\
 5. \text{ a)} \\
 5. \text{ b)} \\
 5. \text{ c)} \\
 6. \text{ a)} \\
 7. \text{ a)} \\
 7. \text{ b)} \\
 7. \text{ c)} \\
 7. \text{ d)} \\
 8. \text{ a)} \\
 8. \text{ b)}
 \end{array}
 \begin{bmatrix}
 0,0315 \\
 0,0496 \\
 0,0641 \\
 0,0250 \\
 0,0503 \\
 0,0434 \\
 0,0387 \\
 0,0576 \\
 0,0561 \\
 0,0333 \\
 0,0272 \\
 0,0655 \\
 0,0416 \\
 0,0293 \\
 0,0409 \\
 0,0496 \\
 0,0659 \\
 0,0177 \\
 0,0463 \\
 0,0282 \\
 0,0293 \\
 0,0576 \\
 0,0511
 \end{bmatrix}
 \tag{8.6}$$

Provjeru konzistentnosti dobivenog globalnog vektora prioriteta kriterija i potkriterija (izraz 8.6) nije potrebno raditi budući da je izračunat na osnovu anketom prikupljenih podataka.


Prioriteti alternativa isti su kao i za proizvodna mikropoduzeća. U tablici 8.8 uz izračunat prioritet alternativa prikazan je i indeks konzistentnosti *CI* i omjer konzistentnosti *CR*.

8.3.3. Konačno rješenje

Množenjem ukupne matrice prioriteta alternativa s vektorom prioriteta kriterija (potkriterija) dobiven je ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata. Navedeni postupak prikazan je izrazom 8.7.

$$\begin{array}{c}
 \text{Vektor prioriteta} \\
 \text{kriterija (potkriterija)}
 \end{array}
 \begin{array}{c}
 \begin{array}{cccc}
 & 1. a) & 1. b) & \dots & 8. b)
 \end{array} \\
 \begin{array}{l}
 5 S \\
 Jidoka \\
 \textbf{JIT} \\
 Kaizen \\
 Kanban \\
 Kontinuirani tok \\
 Map. toka vrijed. \\
 Poka Yoke \\
 SMED \\
 Standard. rad \\
 Taktno vrijeme \\
 TPM
 \end{array}
 \begin{bmatrix}
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,2727 & 0,0452 & & 0,0588 \\
 0,0455 & 0,2203 & & 0,3529 \\
 0,2727 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & \dots & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,3275 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588 \\
 0,0455 & 0,0452 & & 0,0588
 \end{bmatrix}
 \cdot
 \begin{bmatrix}
 0,0315 \\
 0,0496 \\
 0,0641 \\
 0,0250 \\
 0,0503 \\
 0,0434 \\
 0,0387 \\
 0,0576 \\
 0,0561 \\
 0,0333 \\
 0,0272 \\
 0,0655 \\
 0,0416 \\
 0,0293 \\
 0,0409 \\
 0,0496 \\
 0,0659 \\
 0,0177 \\
 0,0463 \\
 0,0282 \\
 0,0293 \\
 0,0576 \\
 0,0511
 \end{bmatrix}
 =
 \begin{bmatrix}
 0,0732 \\
 0,0627 \\
 \textbf{0,1166} \\
 0,1122 \\
 0,0692 \\
 0,1036 \\
 0,0986 \\
 0,0580 \\
 0,0517 \\
 0,1091 \\
 0,0536 \\
 0,0916
 \end{bmatrix}
 \quad (8.7)
 \end{array}$$

Na osnovu ukupnog vektora prioriteta alternativa u odnosu na cilj na slici 8.9 prikazan je *Pareto dijagram* vitkih alata za smanjenje gubitaka u poslovanju hrvatskih proizvodnih malih, srednje velikih i velikih poduzeća.



Slika 8.9. Pareto dijagram vitkih alata za proizvodna mala, srednje velika i velika poduzeća

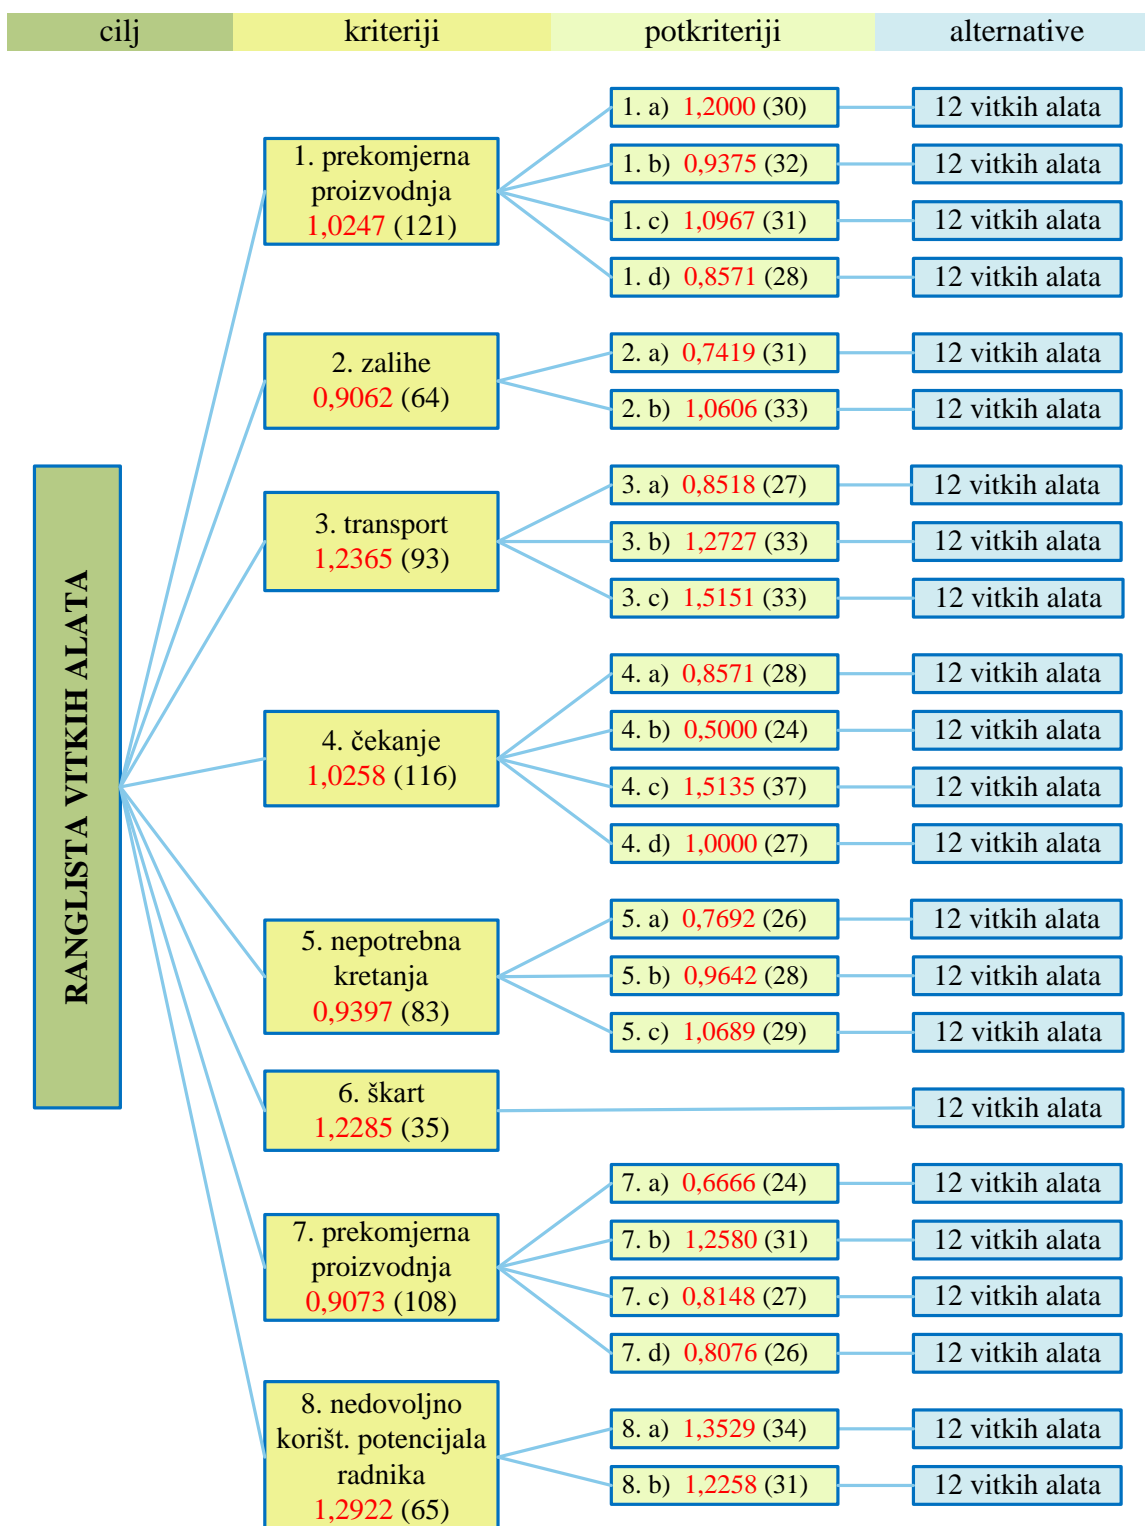
Provedenim istraživanjem došlo se do zaključka da je najpogodniji vitki alat za smanjenje gubitaka u poslovanju hrvatskih proizvodnih malih, srednje velikih i velikih poduzeća "U-pravo-vrijeme" – JIT. Zatim slijede Kaizen, standardizirani rad, kontinuirani tok, i dr. Prema istraživanju najmanji utjecaj na smanjenje gubitaka u poslovanju hrvatskih proizvodnih malih, srednje velikih i velikih poduzeća ima vitki alat brza zamjena alata – SMED.

8.4. Evaluacija pogodnosti primjene vitkih alata za uslužna mikropoduzeća

Kod evaluacije pogodnosti primjene vitkih alata razmatrani su samo odgovori sudionika istraživanja iz uslužnih mikropoduzeća (42 ankete). Postupak evaluacije pogodnosti primjene vitkih alata isti je kao i za proizvodna mikropoduzeća koji je opisan u poglavlju 8.2. Zato je u nastavku naveden skraćeni prikaz postupka:

- hijerarhijska struktura problema – prosječni potencijali prema kriterijima i potkriterijima (slika 8.10)
- izračun prioriteta – normaliziran globalni vektor prioriteta kriterija i potkriterija (izraz 8.8)
- konačno rješenje – ukupni vektor prioriteta alternativa u odnosu na cilj (izraz 8.9) te *Pareto dijagram* (slika 8.11).

8.4.1. Hijerarhijska struktura problema



Slika 8.10. AHP rang lista vitkih alata – uslužna mikropoduzeća– prosječni potencijali prema kriterijima i potkriterijima

Slikom 8.10 prikazana je hijerarhijska struktura problema zajedno s prosječnim potencijalima prema kriterijima i potkriterijima. Radi preglednosti prikaza potkriteriji i alternative (12 vitkih alata) nisu prikazani na slici, nego su navedeni u tablici 8.3 i 8.4 u poglavlju 8.2.1.

8.4.2. Izračun prioriteta

Prema opisanom postupku izračuna prioriteta kriterija i potkriterija za proizvodna mikropoduzeća u poglavlju 8.2.3.1 izračunat je normaliziran globalni vektor prioriteta kriterija i potkriterija za uslužna mikropoduzeća (izraz 8.8).

$$\begin{array}{l}
 1. \text{ a)} \\
 1. \text{ b)} \\
 1. \text{ c)} \\
 1. \text{ d)} \\
 2. \text{ a)} \\
 2. \text{ b)} \\
 3. \text{ a)} \\
 3. \text{ b)} \\
 3. \text{ c)} \\
 4. \text{ a)} \\
 4. \text{ b)} \\
 4. \text{ c)} \\
 4. \text{ d)} \\
 5. \text{ a)} \\
 5. \text{ b)} \\
 5. \text{ c)} \\
 6. \text{ a)} \\
 7. \text{ a)} \\
 7. \text{ b)} \\
 7. \text{ c)} \\
 7. \text{ d)} \\
 8. \text{ a)} \\
 8. \text{ b)}
 \end{array}
 \begin{bmatrix}
 0,0501 \\
 0,0417 \\
 0,0473 \\
 0,0334 \\
 0,0320 \\
 0,0487 \\
 0,0320 \\
 0,0584 \\
 0,0695 \\
 0,0334 \\
 0,0167 \\
 0,0779 \\
 0,0376 \\
 0,0278 \\
 0,0376 \\
 0,0431 \\
 0,0598 \\
 0,0223 \\
 0,0542 \\
 0,0306 \\
 0,0292 \\
 0,0640 \\
 0,0529
 \end{bmatrix}
 \tag{8.8}$$

Provjeru konzistentnosti dobivenog globalnog vektora prioriteta kriterija i potkriterija (izraz 8.8) nije potrebno raditi budući da je izračunat na osnovu anketom prikupljenih podataka.

Prioriteti alternativa isti su kao i za proizvodna mikropoduzeća. U tablici 8.8 uz izračunat prioritet alternativa prikazan je i indeks konzistentnosti CI i omjer konzistentnosti CR .


8.4.3. Konačno rješenje

Množenjem ukupne matrice prioriteta alternativa s vektorom prioriteta kriterija (potkriterija) dobiven je ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata. Navedeni postupak prikazan je izrazom 8.9.

$$\begin{array}{c}
 \text{Vektor prioriteta} \\
 \text{kriterija (potkriterija)}
 \end{array}
 \begin{array}{c}
 \left[\begin{array}{c}
 0,0501 \\
 0,0417 \\
 0,0473 \\
 0,0334 \\
 0,0320 \\
 0,0487 \\
 0,0320 \\
 0,0584 \\
 0,0695 \\
 0,0334 \\
 0,0167 \\
 0,0779 \\
 0,0376 \\
 0,0278 \\
 0,0376 \\
 0,0431 \\
 0,0598 \\
 0,0223 \\
 0,0542 \\
 0,0306 \\
 0,0292 \\
 0,0640 \\
 0,0529
 \end{array} \right]
 \end{array}
 =
 \begin{array}{c}
 \left[\begin{array}{c}
 0,0722 \\
 0,0611 \\
 \mathbf{0,1175} \\
 0,1156 \\
 0,0764 \\
 0,0971 \\
 0,0962 \\
 0,0568 \\
 0,0530 \\
 0,1084 \\
 0,0545 \\
 0,0912
 \end{array} \right]
 \end{array}
 \quad (8.9)$$

	1. a)	1. b)	...	8. b)
5 S	0,0455	0,0452		0,0588
Jidoka	0,0455	0,0452		0,0588
JIT	0,2727	0,0452		0,0588
Kaizen	0,0455	0,2203		0,3529
Kanban	0,2727	0,0452		0,0588
Kontinuirani tok	0,0455	0,0452	...	0,0588
Map. toka vrijed.	0,0455	0,0452		0,0588
Poka Yoke	0,0455	0,0452		0,0588
SMED	0,0455	0,0452		0,0588
Standard. rad	0,0455	0,3275		0,0588
Taktno vrijeme	0,0455	0,0452		0,0588
TPM	0,0455	0,0452		0,0588

Na osnovu ukupnog vektora prioriteta alternativa u odnosu na cilj na slici 8.11 prikazan je *Pareto dijagram* vitkih alata za smanjenje gubitaka u poslovanju hrvatskih uslužnih mikropoduzeća.



Slika 8.11. Pareto dijagram vitkih alata za uslužna mikropoduzeća

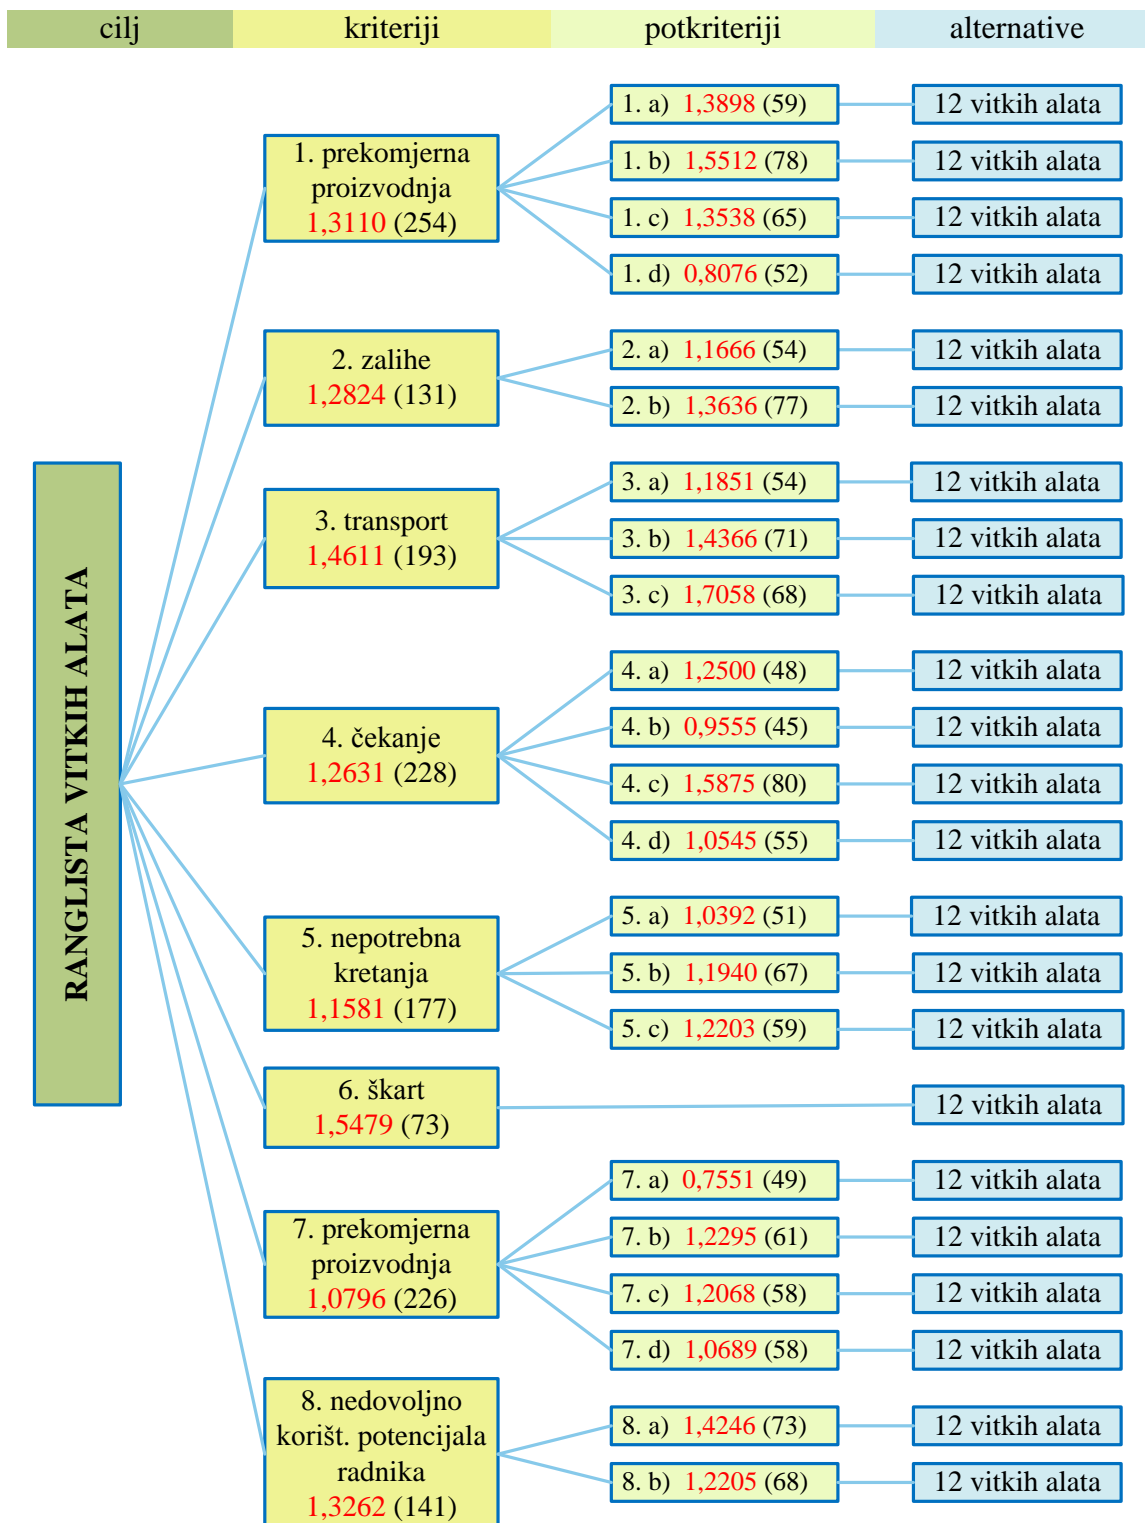
Provedenim istraživanjem došlo se do zaključka da je najpogodniji vitki alat za smanjenje gubitaka u poslovanju hrvatskih uslužnih mikropoduzeća "U-pravo-vrijeme" – JIT. Zatim slijede Kaizen, standardizirani rad, kontinuirani tok, i dr. Prema istraživanju najmanji utjecaj na smanjenje gubitaka u poslovanju hrvatskih uslužnih mikropoduzeća ima vitki alat brza zamjena alata – SMED.

8.5. Evaluacija pogodnosti primjene vitkih alata za uslužna mala, srednje velika i velika poduzeća

Kod evaluacije pogodnosti primjene vitkih alata razmatrani su samo odgovori sudionika istraživanja iz uslužnih malih, srednje velikih i velikih poduzeća (94 ankete). Postupak evaluacije pogodnosti primjene vitkih alata isti je kao i za proizvodna mikropoduzeća koji je opisan u poglavlju 8.2. Zato je u nastavku naveden skraćeni prikaz postupka:

- hijerarhijska struktura problema – prosječni potencijali prema kriterijima i potkriterijima (slika 8.12)
- izračun prioriteta – normaliziran globalni vektor prioriteta kriterija i potkriterija (izraz 8.10)
- konačno rješenje – ukupni vektor prioriteta alternativa u odnosu na cilj (izraz 8.11) te Pareto dijagram (slika 8.13).

8.5.1. Hijerarhijska struktura problema



Slika 8.12. AHP rang lista vitkih alata – uslužna mala, srednje velika i velika poduzeća – prosječni potencijali prema kriterijima i potkriterijima

Slikom 8.12 prikazana je hijerarhijska struktura problema zajedno s prosječnim potencijalima prema kriterijima i potkriterijima. Radi preglednosti prikaza potkriteriji i alternative (12 vitkih alata) nisu prikazani na slici, nego su navedeni u tablici 8.3 i 8.4 u poglavlju 8.2.1.

8.5.2. Izračun prioriteta

Prema opisanom postupku izračuna prioriteta kriterija i potkriterija za proizvodna mikropoduzeća u poglavlju 8.2.3.1 izračunat je normaliziran globalni vektor prioriteta kriterija i potkriterija za uslužna mala, srednja i velika poduzeća (izraz 8.10).

$$\begin{array}{l}
 1. \text{ a)} \\
 1. \text{ b)} \\
 1. \text{ c)} \\
 1. \text{ d)} \\
 2. \text{ a)} \\
 2. \text{ b)} \\
 3. \text{ a)} \\
 3. \text{ b)} \\
 3. \text{ c)} \\
 4. \text{ a)} \\
 4. \text{ b)} \\
 4. \text{ c)} \\
 4. \text{ d)} \\
 5. \text{ a)} \\
 5. \text{ b)} \\
 5. \text{ c)} \\
 6. \text{ a)} \\
 7. \text{ a)} \\
 7. \text{ b)} \\
 7. \text{ c)} \\
 7. \text{ d)} \\
 8. \text{ a)} \\
 8. \text{ b)}
 \end{array}
 \begin{bmatrix}
 0,0451 \\
 0,0665 \\
 0,0484 \\
 0,0231 \\
 0,0346 \\
 0,0577 \\
 0,0424 \\
 0,0526 \\
 0,0599 \\
 0,0330 \\
 0,0236 \\
 0,0698 \\
 0,0319 \\
 0,0291 \\
 0,0440 \\
 0,0396 \\
 0,0621 \\
 0,0203 \\
 0,0412 \\
 0,0385 \\
 0,0341 \\
 0,0571 \\
 0,0456
 \end{bmatrix}
 \quad (8.10)$$

Provjeru konzistentnosti dobivenog globalnog vektora prioriteta kriterija i potkriterija (izraz 8.10) nije potrebno raditi budući da je izračunat na osnovi podataka prikupljenih anketom.

Prioriteti alternativa isti su kao i za proizvodna mikropoduzeća. U tablici 8.8 uz izračunat prioritet alternativa prikazan je i indeks konzistentnosti *CI* i omjer konzistentnosti *CR*.


8.5.3. Konačno rješenje

Množenjem ukupne matrice prioriteta alternativa s vektorom prioriteta kriterija (potkriterija) dobiven je ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata. Navedeni postupak prikazan je izrazom 8.11.

$$\begin{array}{c}
 \text{Vektor prioriteta} \\
 \text{kriterija (potkriterija)}
 \end{array}
 \begin{array}{c}
 \left[\begin{array}{c}
 0,0451 \\
 0,0665 \\
 0,0484 \\
 0,0231 \\
 0,0346 \\
 0,0577 \\
 0,0424 \\
 0,0526 \\
 0,0599 \\
 0,0330 \\
 0,0236 \\
 0,0698 \\
 0,0319 \\
 0,0291 \\
 0,0440 \\
 0,0396 \\
 0,0621 \\
 0,0203 \\
 0,0412 \\
 0,0385 \\
 0,0341 \\
 0,0571 \\
 0,0456
 \end{array} \right]
 \end{array}
 =
 \begin{array}{c}
 \left[\begin{array}{c}
 0,0741 \\
 0,0615 \\
 0,1143 \\
 \mathbf{0,1170} \\
 0,0742 \\
 0,0992 \\
 0,1020 \\
 0,0570 \\
 0,0509 \\
 0,1116 \\
 0,0529 \\
 \mathbf{0,0853}
 \end{array} \right]
 \end{array}
 \quad (8.11)$$

	1. a)	1. b)	...	8. b)
5 S	0,0455	0,0452		0,0588
Jidoka	0,0455	0,0452		0,0588
JIT	0,2727	0,0452		0,0588
Kaizen	0,0455	0,2203		0,3529
Kanban	0,2727	0,0452		0,0588
Kontinuirani tok	0,0455	0,0452	...	0,0588
Map. toka vrijed.	0,0455	0,0452		0,0588
Poka Yoke	0,0455	0,0452		0,0588
SMED	0,0455	0,0452		0,0588
Standard. rad	0,0455	0,3275		0,0588
Taktno vrijeme	0,0455	0,0452		0,0588
TPM	0,0455	0,0452		0,0588

Na osnovu ukupnog vektora prioriteta alternativa u odnosu na cilj na slici 8.13 prikazan je *Pareto dijagram* vitkih alata za smanjenje gubitaka u poslovanju hrvatskih uslužnih malih, srednje velikih i velikih poduzeća.



Slika 8.13. Pareto dijagram vitkih alata za uslužna mala, srednje velika i velika poduzeća

Provedenim istraživanjem došlo se do zaključka da je najpogodniji vitki alat za smanjenje gubitaka u poslovanju hrvatskih uslužnih malih, srednje velikih i velikih poduzeća Kaizen. Zatim slijede "U-pravo-vrijeme"– JIT, standardizirani rad, mapiranje toka vrijednosti i dr. Prema istraživanju najmanji utjecaj na smanjenje gubitaka u poslovanju hrvatskih uslužnih malih, srednje velikih i velikih poduzeća ima vitki alat brza zamjena alata – SMED.

9. MODEL UČINKOVITOGA UPRAVLJANJA PODUZEĆEM

Provedenim istraživanjem te evaluacijom vitkih alata prema pokazateljima poduzeća dobivene su rang liste najpogodnijih vitkih alata (slika 8.7, 8.9, 8.11, 8.13) s gledišta utjecaja na smanjenje gubitaka u poslovanju hrvatskih poduzeća. Međutim, dobiveni najpogodniji vitki alat prema pokazateljima poduzeća ne znači da je njegova implementacija optimalan izbor za smanjenje gubitaka u poslovanju poduzeća, jer je potrebno uzeti u obzir i mnoge druge čimbenike, poput troška i potrebnog vremena implementacije, potrebne organizacijske promjene u poduzeću i dr.

Podaci o financijskim čimbenicima te organizacijskim čimbenicima kod implementacije analiziranih 12 vitkih alata dobivene su od ekspertne grupe ispitanika (s velikim iskustvom implementacije vitke metodologije u hrvatska poduzeća) putem ankete "Implementacija vitkih alata". Primjenom AHP metode izračunati su vektori prioriteta alternativa (vitkih alata) prema kriterijima – financijski i organizacijski čimbenici.

Odabir vitkog alata koji će se primijeniti za smanjenje gubitaka u poslovanju pojedinog poduzeća svakako ovisi o tome koji će prioritet vrhovni menadžment poduzeća dodijeliti pojedinim čimbenicima. Time se dobiva vektor prioriteta vrhovnog menadžmenta, koji je sastavni dio modela učinkovitoga upravljanja poduzećem opisanog u nastavku.

9.1. Čimbenici odabira vitkih alata

Istraživanjem stručne literature vezane uz primjenu AHP metode kod implementacije vitkih alata navedenih u poglavlju 5.2.1, drugi autori [71, 72] također su razmatrali čimbenike koji utječu na implementaciju vitkih alata.

Kao što je opisano u radu [71] autori su razmatrali tri načina implementacije vitkih alata u zdravstvene ustanove: vanjski konzultanti, studenti – putem studentskih projekata i zaposlenici zdravstvenih ustanova. Kao ključni čimbenici za odabir najprikladnijeg rješenja kod implementacije vitkih alata (7 gubitaka prema vitkoj metodologiji, Kaizen, Kanban, 5 S, Poka Yoke) u zdravstvene ustanove u Iranu razmatrani su trošak i vrijeme implementacije. Za

odabir najprikladnijeg rješenja primijenjena je AHP metoda u kojoj su trošak i vrijeme implementacije uzeti su u obzir kod izračuna matrica s težinskim faktorom od 0,3 za cijenu i 0,7 za vrijeme implementacije vitkih alata.

Provedenim istraživanjem čimbenika koji utječu na implementaciju vitke metodologije u proizvodna mikropoduzeća, mala i srednje velika proizvodna poduzeća opisana u radu [72] autori su došli do sljedećih saznanja. Od gotovo 30 znatnih čimbenika koji su analizirani, provedenim istraživanjem došlo se do 11 kritičnih čimbenika uspješnosti implementacije vitke metodologije u navedena poduzeća. Navedeni čimbenici uspješnosti zajedno s ponderima prikazani su u tablici 9.1.

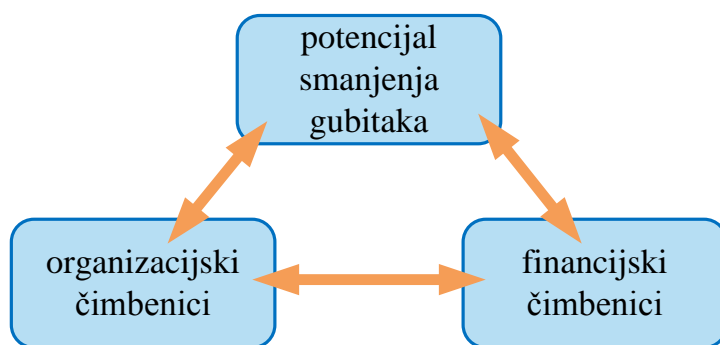
Tablica 9.1. Ponderi kritičnih čimbenika uspješnosti [72]

Kritični čimbenik uspješnosti	Ponder
učinkovito vodstvo	0,0990
spremnost organizacije na promjene	0,1078
uključenost zaposlenika	0,0891
spremnost za učenje	0,0836
financijske mogućnosti poduzeća	0,1144
podrška i uključenost vrhovnog menadžmenta	0,1089
kontinuirana evaluacija	0,1023
obrazovanje i usavršavanje zaposlenika	0,0946
dijeljenje stečenih znanja	0,1045
poboljšanje poslovne suradnje s klijentima	0,1067
"lean" konzultant	0,0847

Kao i u radu [71] kritični čimbenici uspješnosti navedeni u tablici 9.1 mogu se grupirati u dvije grupe: financijski i organizacijski čimbenici. Kritični čimbenici iz tablice 9.1 koji utječu na uspješnost implementacije vitkih alata, a znatnije ovise o financijskim sredstvima jesu: financijske mogućnosti tvrtke, kontinuirana evaluacija, sveobuhvatno obrazovanje i usavršavanje te "lean" konzultant. Za navedene grupe izračunati su težinski faktori: 0,36 za financijske čimbenike i 0,64 za organizacijske čimbenike. Izračunati težinski faktori malo se razlikuju od težinskih faktora za cijenu (0,3) i vrijeme (0,7) implementacije vitkih alata upotrijebljenih u radu [71].

Na osnovi saznanja drugih autora [71, 72], u ovom radu kao najvažniji čimbenici za odabir vitkih alata prilikom implementacije u neko poduzeće kod izrade modela učinkovitoga upravljanja poduzećem razmatrani su: (slika 9.1)

- potencijal smanjenja gubitaka u poslovanju poduzeća
- financijski čimbenici (cijena implementacije)
- organizacijski čimbenici (organizacijske promjene za uspješnu implementaciju – složenost implementacije).



Slika 9.1. Najvažniji čimbenici odabira vitkog alata

Ukupni vektori prioriteta prema pokazateljima poduzeća izračunati su u poglavlju 8. i predstavljaju potencijale analiziranih vitkih alata za smanjenje gubitaka u poslovanju poduzeća. Kao što je navedeno, u najvažnije čimbenike kod odabira vitkih alata prilikom implementacije u poduzeće spadaju i financijski i organizacijski čimbenici. U nastavku rada opisan je postupak dobivanja vektora prioriteta financijskih čimbenika i organizacijskih čimbenika prema alternativama (12 vitkih alata) primjenom AHP metode.

9.1.1. Potencijal smanjenja gubitaka u poslovanju poduzeća

U poglavlju 8. provedenom evaluacijom vitkih alata prema pokazateljima poduzeća dobiveni su ukupni vektori prioriteta alternativa u odnosu na cilj, odnosno rang liste alternativa – vitkih alata (izraz 8.5, 8.7, 8.9 i 8.11) koji su prikazani u matričnom obliku izrazom 9.1.

	proizvodna mikro	proizvodna ostala	uslužna mikro	uslužna ostala	
5 S	0,0719	0,0732	0,0722	0,0741	(9.1)
Jidoka	0,0632	0,0627	0,0611	0,0615	
JIT	0,1282	0,1166	0,1175	0,1143	
Kaizen	0,1107	0,1122	0,1156	0,1170	
Kanban	0,0793	0,0692	0,0764	0,0742	
Kontinuirani tok	0,1008	0,1036	0,0971	0,0992	
Map. toka vrijed.	0,0934	0,0986	0,0962	0,1020	
Poka Yoke	0,0584	0,0580	0,0568	0,0570	
SMED	0,0564	0,0517	0,0530	0,0509	
Standard. rad	0,0899	0,1091	0,1084	0,1116	
Taktno vrijeme	0,0575	0,0536	0,0545	0,0529	
TPM	0,0904	0,0916	0,0912	0,0853	

Navedeni ukupni vektori prioriteta prema pokazateljima poduzeća predstavljaju pogodnost (potencijal) analiziranih 12 vitkih alata za smanjenje gubitaka u poslovanju poduzeća.

9.1.2. Financijski čimbenici implementacije vitkih alata

Trošak implementacije vitkog alata u poduzeće svakako je vrlo važan čimbenik koji utječe na odabir vitkog alata. Financijski čimbenik obuhvaća troškove: vanjskih konzultanata, obrazovanja i usavršavanja zaposlenika, opreme i sredstava za implementaciju vitkog alata te dr. Podaci o trošku implementacije za analiziranih 12 vitkih alata nisu prikazani sa iznosom troška prema svakom od pokazatelja poduzeća, nego su provedenom anketom "Implementacija vitkih alata" usporedbom u parovima dobiveni odnosi troška implementacije između analiziranih vitkih alata. Anketa "Implementacija vitkih alata" nalazi se u Prilogu rada.

Na osnovi podataka prikupljenih anketom primjenom AHP metode dobiven je vektor prioriteta alternativa (12 vitkih alata) prema financijskom čimbeniku (ukupno gledajući sve financijske čimbenike) primjenjiv za sve pokazatelje poduzeća – proizvodna mikropoduzeća, proizvodna ostala (mala, srednje velika i velika) poduzeća, uslužna mikropoduzeća, uslužna ostala (mala, srednje velika i velika) poduzeća.

9.1.2.1. Usporedba alternativa (vitkih alata) u parovima

Anketa "Implementacija vitkih alata" provedena je na ciljanoj ekspertnoj grupi od 8 sudionika istraživanja s dugogodišnjim iskustvom u implementaciji vitkih alata u hrvatskim proizvodnim i uslužnim poduzećima. Sudionici istraživanja ekspertne grupe bili su: sveučilišni profesori, asistenti Katedre za upravljanje proizvodnjom (FSB, Zagreb), *lean* implementatori iz poduzeća Končar energetski transformatori d.o.o. i Elektro-Kontakt d.d.. Anketom su dobiveni podaci usporedbe alternativa (12 vitkih alata) prema financijskom čimbeniku. Iz prethodnog iskustva prikupljanja podataka putem ankete (Anketa: Upravljanje poduzećima u RH) od sudionika istraživanja tražilo se samo da usporede u parovima prema financijskom čimbeniku vitki alat 5 S s ostalih 11 vitkih alata prema *Saatyjevoj skali*. Usporedba u parovima rađena je prema kriteriju financijski čimbenik s minimizirajućim ciljem – odnosno, koji je od uspoređivanih alata bolje upotrijebiti s obzirom na financijski čimbenik (manji trošak implementacije). Međuodnos ostalih vitkih alata izračunat je na osnovi prikupljenih podataka. Matrica usporedbe alternativa (sa srednjim vrijednostima prikupljenih podataka) za kriterij financijski čimbenik prikazana je u tablici 9.2.

Tablica 9.2. Matrica usporedbe alternativa prema kriteriju financijski čimbenik


	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	6	7	1	6	7	3	5	5	2	1	5
Jidoka	1/6	1	2	1/6	1	2	1/3	1/2	1/2	1/4	1/6	1/2
JIT	1/7	1/2	1	1/7	1/2	1	1/4	1/3	1/3	1/5	1/7	1/3
Kaizen	1	6	7	1	6	7	3	5	5	2	1	5
Kanban	1/6	1	2	1/6	1	2	1/3	1/2	1/2	1/4	1/6	1/2
Kont. tok	1/7	1/2	1	1/7	1/2	1	1/4	1/2	1/2	1/5	1/7	1/3
Map. toka vr.	1/3	3	4	1/3	3	4	1	3	3	1/2	1/3	3
Poka Yoke	1/5	2	3	1/5	2	2	1/3	1	1	1/3	1/5	1
SMED	1/5	2	3	1/5	2	2	1/3	1	1	1/3	1/5	1
Standard. rad	1/2	4	5	1/2	4	5	2	3	3	1	1/2	3
Taktno vr.	1	6	7	1	6	7	3	5	5	2	1	5
TPM	1/5	2	3	1/5	2	3	1/3	1	1	1/3	1/5	1

9.1.2.2. Izračun prioriteta alternativa

Prema postupku opisanom u poglavlju 8.1.3.1 izračunati je vektor prioriteta alternativa (12 vitkih alata) prema kriteriju financijski čimbenik (izraz 9.2).

5 S	0,1918	(9.2)
Jidoka	0,0290	
JIT	0,0189	
Kaizen	0,1918	
Kanban	0,0290	
Kontinuirani tok	0,0204	
Map. toka vrijed.	0,0829	
Poka Yoke	0,0428	
SMED	0,0428	
Standard. rad	0,1149	
Taktno vrijeme	0,1918	
TPM	0,0441	

Budući da je rađena matrica usporedbe prema *Saatyjevoj skali*, za izračunati prioritet alternativa provjerena je njegova konzistentnost prema postupku opisanom u poglavlju 8.1.3.2. Za izračunatu maksimalnu vrijednost matrice ($\lambda_{\max} = 12,2727$), indeks konzistentnosti ($CI = 0,0247$) i omjer konzistentnosti ($CR = 0,0167$) može se zaključiti da su procjene relativnih važnosti alternativa prihvatljive, odnosno konzistentne ($CR \leq 0,10$). Na osnovu vektora prioriteta alternativa prema kriteriju financijski čimbenik na slici 9.2 prikazan je *Pareto dijagram* vitkih alata prema financijskom čimbeniku – trošku implementacije (od manjeg prema većem).



Slika 9.2. Pareto dijagram vitkih alata prema financijskom čimbeniku od manjeg prema većem

Obradom podataka prikupljenih od ekspertne grupe stručnjaka došlo se do zaključka da se analizirani vitki alati 5 S, Kaizen i taktno vrijeme mogu implementirati uz najmanje troškove. Zatim slijede standardizirani rad, mapiranje toka vrijednosti, i dr. Od analiziranih 12 vitkih alata došlo se do zaključka da "Proizvodnja u pravo vrijeme – JIT" prilikom implementacije zahtijeva najveće financijske izdatke.

9.1.3. Organizacijski čimbenici implementacije vitkih alata

Organizacijskim čimbenikom obuhvaćeni su: vodstvo poduzeća, spremnost organizacije na promjene, uključenost zaposlenika kod implementacije vitkog alata i dr. Kao i za financijski čimbenik, provedenom anketom "Implementacija vitkih alata" i usporedbom vitkih alata u parovima prema organizacijskom čimbeniku dobiveni su odnosi između analiziranih vitkih alata.

Na osnovi podataka prikupljenih anketom primjenom AHP metode dobiven je vektor prioriteta alternativa (12 vitkih alata) prema organizacijskom čimbeniku primjenljiv na sve pokazatelje poduzeća – proizvodna mikropoduzeća, proizvodna ostala (mala, srednje velika i velika) poduzeća, uslužna mikropoduzeća, uslužna ostala (mala, srednje velika i velika) poduzeća.

9.1.3.1. Usporedba alternativa (vitkih alata) u parovima

Prema opisanom postupku dobivanja matrice usporedbe za kriterij financijski čimbenik (poglavlje 9.1.2.1) dobivena je matrica usporedbe vitkih alata za kriterij organizacijski čimbenik, koja je prikazana u tablici 9.3. Važno je za napomenuti da je usporedba u parovima rađena je prema kriteriju organizacijski čimbenik s minimizirajućim ciljem – odnosno, koji je od uspoređivanih alata bolje upotrijebiti s obzirom na organizacijski čimbenik (zahtijeva manje organizacijske promjene kod implementacije – manja složenost implementacije).

Tablica 9.3. Matrica usporedbe alternativa prema kriteriju organizacijski čimbenik

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	4	7	3	6	5	5	3	5	4	2	5
Jidoka	1/4	1	3	1/2	3	2	2	1/2	2	1	1/3	2
JIT	1/7	1/3	1	1/4	1/2	1/3	1/3	1/5	1/3	1/4	1/5	1/3
Kaizen	1/3	2	4	1	4	3	3	1	3	2	1/4	3
Kanban	1/6	1/3	2	1/4	1	1/2	1/2	1/4	1/2	1/3	1/5	1/2
Kont. tok	1/5	1/2	3	1/3	2	1	1	1/3	1	1/2	1/4	1
Map. toka vr.	1/5	1/2	3	1/3	2	1	1	1/3	1	1/2	1/4	1
Poka Yoke	1/3	2	5	1	4	3	3	1	4	3	1/4	5
SMED	1/5	1/2	3	1/3	2	1	1	1/4	1	1/3	1/4	1
Standard. rad	1/4	1	4	1/2	3	2	1/3	1/3	3	1	1/5	3
Taktno vr.	1/2	3	5	4	5	5	5	4	4	5	1	5
TPM	1/5	1/2	3	1/3	2	1	1	1/5	1	1/3	1/5	1

9.1.3.2. Izračun prioriteta alternativa


Prema postupku opisanom u poglavlju 8.1.3.1 izračunati je vektor prioriteta alternativa (12 vitkih alata) prema kriteriju organizacijski čimbenik (izraz 9.3).

$$\begin{array}{l}
 5\ S \\
 Jidoka \\
 JIT \\
 Kaizen \\
 Kanban \\
 Kontinuirani tok \\
 Map. toka vrijed. \\
 Poka Yoke \\
 SMED \\
 Standard. rad \\
 Taktno vrijeme \\
 TPM
 \end{array}
 \begin{bmatrix}
 0,2357 \\
 0,0711 \\
 0,0191 \\
 0,1038 \\
 0,0268 \\
 0,0436 \\
 0,0436 \\
 0,1138 \\
 0,0404 \\
 0,0687 \\
 0,1947 \\
 0,0386
 \end{bmatrix}
 \quad (9.3)$$

Budući da je rađena matrica usporedbe prema *Saatyjevoj skali*, za izračunati prioritet alternativa provjerena je njegova konzistentnost prema postupku opisanom u poglavlju

8.1.3.2. Za izračunatu maksimalnu vrijednost matrice ($\lambda_{\max} = 12,5173$), indeks konzistentnosti ($CI = 0,0470$) i omjera konzistentnosti ($CR = 0,0317$) može se zaključiti da su procjene relativnih važnosti alternativa prihvatljive, odnosno konzistentne ($CR \leq 0,10$).

Na osnovi vektora prioriteta alternativa prema kriteriju organizacijski čimbenik na slici 9.3 prikazan je *Pareto dijagram* vitkih alata prema organizacijskom čimbeniku – potrebne organizacijske promjene prilikom implementacije (od manjih prema većim).



Slika 9.3. Pareto dijagram vitkih alata prema organizacijskom čimbeniku od manjih prema većima

Obradom podataka prikupljenih od ekspertne grupe stručnjaka došlo se do zaključka da implementacija vitkog alata 5 S zahtijeva najmanje organizacijske promjene. Zatim slijede vitki alati taktno vrijeme, Poka Yoke i dr. Od analiziranih 12 vitkih alata dobiveno je da "Proizvodnja u pravo vrijeme – JIT" prilikom implementacije zahtijeva najveće organizacijske promjene.

9.2. Opći model učinkovitoga upravljanja poduzećem


Provedenim istraživanjem i analizama podataka prikupljenih anketom "Upravljanje poduzećima u RH" dobiveni su ukupni vektori prioriteta analiziranih vitkih alata (izraz 8.5, 8.7, 8.9 i 8.11) prema pokazateljima poduzeća: proizvodna mikropoduzeća, proizvodna ostala (mala, srednje velika i velika) poduzeća, uslužna mikropoduzeća, uslužna ostala (mala,

srednje velika i velika) poduzeća. Dobiveni ukupni vektori prioriteta predstavljaju najpogodnije vitke alate za smanjenje gubitaka u poslovanju poduzeća. Navedeni ukupni vektori prioriteta u matičnom obliku prikazani su izrazom 9.1.


Provedenom anketom "Implementacija vitkih alata", od ciljane ekspertne grupe stručnjaka s dugogodišnjim iskustvom u implementaciji vitkih alata u hrvatska poduzeća dobiveni su vektori prioriteta analiziranih vitkih alata prema kriterijima financijski čimbenik i organizacijski čimbenik prilikom implementacije navedenih vitkih alata u hrvatska poduzeća (izraz 9.2 i 9.3).

Na osnovu prethodno navedenih podataka izrađen je opći model učinkovitoga upravljanja poduzećem prikazan izrazom 9.4.


$$\begin{array}{c}
 \begin{array}{c} 5 \text{ S} \\ \vdots \\ 12 \text{ vitkih alata} \\ \vdots \\ \text{TPM} \end{array}
 \end{array}
 \left[\begin{array}{c} \left[\begin{array}{c} \text{Ukupni vektor prioriteta} \\ \text{po pokazateljima poduzeća} \end{array} \right] \\ \left[\begin{array}{c} \text{Vektor prioriteta po kriteriju} \\ \text{financijski čimbenik} \end{array} \right] \\ \left[\begin{array}{c} \text{Vektor prioriteta po kriteriju} \\ \text{organizacijski čimbenik} \end{array} \right] \end{array} \right] \cdot \left[\begin{array}{c} \text{Vektor prioriteta vrhovnog} \\ \text{menadžmenta poduzeća} \end{array} \right] = \left[\begin{array}{c} \text{Vektor prioriteta alternativa u} \\ \text{odnosu na cilj (12 vitkih alata)} \end{array} \right] \quad (9.4)$$




Ulaz iz podataka o upravljanju poduzećima u RH prikupljenih anketom



Ulaz iz empirijskih spoznaja stručnjaka (ekspertne grupe)



Ulaz pojedine tvrtke (prioriteti vrhovnog menadžmenta poduzeća)



Rang lista vitkih alata za promatrano poduzeće

U navedeni opći model učinkovitoga upravljanja poduzećem (izraz 9.4) uključeni su najvažniji čimbenici kod odabira vitkih alata prilikom implementacije u neko poduzeće i definirani su u poglavlju 9.1. Navedeni najvažniji čimbenici jesu:

- potencijal smanjenja gubitaka u poslovanju poduzeća – u modelu su obuhvaćeni ukupnim vektorom prioriteta prema pokazateljima poduzeća (izraz 8.5, 8.7, 8.9 i 8.11)
- financijski čimbenik – u modelu su obuhvaćeni vektorom prioriteta prema kriteriju financijski čimbenik (izraz 9.2)
- organizacijski čimbenik – u modelu su obuhvaćeni vektorom prioriteta prema kriteriju organizacijski čimbenik (izraz 9.3).

Za dobivanje vektora prioriteta alternativa u odnosu na cilj – najpogodniji vitki alati za implementaciju u pojedino poduzeće, prema izrazu 9.4 potrebno je izračunati i vektor prioriteta vrhovnog menadžmenta. Usporedbom čimbenika (potencijal smanjenja gubitaka, financijski čimbenik, organizacijski čimbenik) u parovima prema *Saatyjevoj skali* vrhovni menadžment daje prioritet pojedinim čimbenicima. Na primjer, ako je cijena implementacije vitkih alata bitan čimbenik, usporedbom u parovima dodjeljuje joj se veći broj prema *Saatyjevoj skali*. Time se daje prioritet vitkim alatima koji su financijski manje zahtjevni kod implementacije, budući da je rađena usporedba u parovima prema kriteriju financijski čimbenik s minimizirajućim ciljem. Prema postupku opisanom u poglavlju 8.1.3.1 izračuna se vektor prioriteta vrhovnog menadžmenta. Budući da je matrica usporedbe (3 x 3) rađena prema *Saatyjevoj skali*, potrebna je i provjera konzistentnosti prema postupku opisanom u poglavlju 8.1.3.2.

Množenjem matrice prioriteta (vektori prioriteta: prema pokazatelju poduzeća, financijskom i organizacijskom čimbeniku) s vektorom prioriteta vrhovnog menadžmenta poduzeća dobiva se ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata za promatrano poduzeće.

Na osnovu općeg modela učinkovitoga upravljanja poduzećem (izraz 9.4) u nastavku se daje prikaz modela učinkovitoga upravljanja za svaki od pokazatelja poduzeća: proizvodna mikropoduzeća, proizvodna ostala (mala, srednje velika i velika) poduzeća, uslužna mikropoduzeća, uslužna ostala (mala, srednje velika i velika) poduzeća.

9.2.1. Model učinkovitoga upravljanja proizvodnim mikropoduzećima

Uvrštenjem ukupnog vektora prioriteta za proizvodna mikropoduzeća (izraz 8.5), vektora prioriteta prema kriteriju financijski čimbenik (izraz 9.2) i vektora prioriteta prema kriteriju organizacijski čimbenik (izraz 9.3) u opći model učinkovitoga upravljanja poduzećem (izraz 9.4) dobiva se model učinkovitoga upravljanja proizvodnim mikropoduzećima (izraz 9.5).

$$\begin{array}{c}
 \text{5 S} \\
 \text{Jidoka} \\
 \text{JIT} \\
 \text{Kaizen} \\
 \text{Kanban} \\
 \text{Kontinuirani tok} \\
 \text{Map. toka vrijed.} \\
 \text{Poka Yoke} \\
 \text{SMED} \\
 \text{Standard. rad} \\
 \text{Taktno vrijeme} \\
 \text{TPM}
 \end{array}
 \begin{array}{c}
 \text{izraz 8.5} \\
 \left[\begin{array}{c} 0,0719 \\ 0,0632 \\ 0,1282 \\ 0,1107 \\ 0,0793 \\ 0,1008 \\ 0,0934 \\ 0,0584 \\ 0,0564 \\ 0,0899 \\ 0,0575 \\ 0,0904 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.2} \\
 \left[\begin{array}{c} 0,1918 \\ 0,0290 \\ 0,0189 \\ 0,1918 \\ 0,0290 \\ 0,0204 \\ 0,0829 \\ 0,0428 \\ 0,0428 \\ 0,1149 \\ 0,1918 \\ 0,0441 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.3} \\
 \left[\begin{array}{c} 0,2357 \\ 0,0711 \\ 0,0191 \\ 0,1038 \\ 0,0268 \\ 0,0436 \\ 0,0436 \\ 0,1138 \\ 0,0404 \\ 0,0687 \\ 0,1947 \\ 0,0386 \end{array} \right]
 \end{array}
 \cdot
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta vrhovnog} \\ \text{menadžmenta poduzeća} \end{array} \right]
 \end{array}
 =
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta alternativa u} \\ \text{odnosu na cilj (12 vitkih alata)} \end{array} \right]
 \end{array}
 \quad (9.5)$$

Za dobivanje vektora prioriteta alternativa u odnosu na cilj – najpogodnijih vitkih alata za proizvodna mikropoduzeća potrebno je izračunati vektor prioriteta vrhovnog menadžmenta poduzeća. Na taj način vrhovni menadžment poduzeća usporedbom čimbenika (potencijal smanjenja gubitaka, financijski čimbenik, organizacijski čimbenik) u parovima prema *Saatyjevoj skali* daje prioritet pojedinim čimbenicima. Postupak izračuna vektora prioriteta opisan je u poglavlju 8.1.3.1 i 8.1.3.2.

Množenjem matrice prioriteta (vektori prioriteta: prema pokazatelju proizvodna mikropoduzeća (izraz 8.5), financijskog (izraz 9.2) čimbenika i organizacijskog (izraz 9.3) čimbenika s vektorom prioriteta vrhovnog menadžmenta poduzeća dobiva se ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata za promatrano proizvodno mikropoduzeće.

9.2.2. Model učinkovitoga upravljanja proizvodnim malim, srednje velikim i velikim poduzećima

Uvrštenjem ukupnog vektora prioriteta za proizvodna mala, srednje velika i velika poduzeća (izraz 8.7), vektora prioriteta prema kriteriju financijski čimbenik (izraz 9.2) i vektora prioriteta prema kriteriju organizacijski čimbenik (izraz 9.3) u opći model učinkovitoga upravljanja poduzećem (izraz 9.4) dobiva se model učinkovitoga upravljanja proizvodnim malim, srednje velikim i velikim poduzećima (izraz 9.6).

$$\begin{array}{l}
 \text{5 S} \\
 \text{Jidoka} \\
 \text{JIT} \\
 \text{Kaizen} \\
 \text{Kanban} \\
 \text{Kontinuirani tok} \\
 \text{Map. toka vrijed.} \\
 \text{Poka Yoke} \\
 \text{SMED} \\
 \text{Standard. rad} \\
 \text{Taktno vrijeme} \\
 \text{TPM}
 \end{array}
 \begin{array}{c}
 \text{izraz 8.7} \\
 \left[\begin{array}{c} 0,0732 \\ 0,0627 \\ 0,1166 \\ 0,1122 \\ 0,0692 \\ 0,1036 \\ 0,0986 \\ 0,0580 \\ 0,0517 \\ 0,1091 \\ 0,0536 \\ 0,0916 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.2} \\
 \left[\begin{array}{c} 0,1918 \\ 0,0290 \\ 0,0189 \\ 0,1918 \\ 0,0290 \\ 0,0204 \\ 0,0829 \\ 0,0428 \\ 0,0428 \\ 0,1149 \\ 0,1918 \\ 0,0441 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.3} \\
 \left[\begin{array}{c} 0,2357 \\ 0,0711 \\ 0,0191 \\ 0,1038 \\ 0,0268 \\ 0,0436 \\ 0,0436 \\ 0,1138 \\ 0,0404 \\ 0,0687 \\ 0,1947 \\ 0,0386 \end{array} \right]
 \end{array}
 \cdot
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta vrhovnog} \\ \text{menadžmenta poduzeća} \end{array} \right]
 \end{array}
 =
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta alternativa u} \\ \text{odnosu na cilj (12 vitkih alata)} \end{array} \right]
 \end{array}
 \quad (9.6)$$

Za dobivanje vektora prioriteta alternativa u odnosu na cilj – najpogodnijih vitkih alata za proizvodna mala, srednje velika i velika poduzeća potrebno je izračunati vektor prioriteta vrhovnog menadžmenta poduzeća. Na taj način vrhovni menadžment poduzeća usporedbom čimbenika (potencijal smanjenja gubitaka, financijski čimbenik, organizacijski čimbenik) u parovima prema *Saatyjevoj skali* daje prioritet pojedinim čimbenicima. Postupak izračuna vektora prioriteta opisan je u poglavlju 8.1.3.1 i 8.1.3.2.

Množenjem matrice prioriteta (vektori prioriteta: prema pokazatelju proizvodna mala, srednje velika i velika poduzeća (izraz 8.7), financijskog (izraz 9.2) čimbenika i organizacijskog (izraz 9.3) čimbenika) s vektorom prioriteta vrhovnog menadžmenta poduzeća dobiva se ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata za promatrano proizvodno malo, srednje veliko ili veliko poduzeće.

9.2.3. Model učinkovitoga upravljanja uslužnim mikropoduzećima

Uvrštenjem ukupnog vektora prioriteta za uslužna mikropoduzeća (izraz 8.9), vektora prioriteta prema kriteriju financijski čimbenik (izraz 9.2) i vektora prioriteta prema kriteriju organizacijski čimbenik (izraz 9.3) u opći model učinkovitoga upravljanja poduzećem (izraz 9.4) dobiva se model učinkovitoga upravljanja uslužnim mikropoduzećima (izraz 9.7).

$$\begin{array}{l}
 \text{5 S} \\
 \text{Jidoka} \\
 \text{JIT} \\
 \text{Kaizen} \\
 \text{Kanban} \\
 \text{Kontinuirani tok} \\
 \text{Map. toka vrijed.} \\
 \text{Poka Yoke} \\
 \text{SMED} \\
 \text{Standard. rad} \\
 \text{Taktno vrijeme} \\
 \text{TPM}
 \end{array}
 \begin{array}{c}
 \text{izraz 8.9} \\
 \left[\begin{array}{c} 0,0722 \\ 0,0611 \\ 0,1175 \\ 0,1156 \\ 0,0764 \\ 0,0971 \\ 0,0962 \\ 0,0568 \\ 0,0530 \\ 0,1084 \\ 0,0545 \\ 0,0912 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.2} \\
 \left[\begin{array}{c} 0,1918 \\ 0,0290 \\ 0,0189 \\ 0,1918 \\ 0,0290 \\ 0,0204 \\ 0,0829 \\ 0,0428 \\ 0,0428 \\ 0,1149 \\ 0,1918 \\ 0,0441 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.3} \\
 \left[\begin{array}{c} 0,2357 \\ 0,0711 \\ 0,0191 \\ 0,1038 \\ 0,0268 \\ 0,0436 \\ 0,0436 \\ 0,1138 \\ 0,0404 \\ 0,0687 \\ 0,1947 \\ 0,0386 \end{array} \right]
 \end{array}
 \cdot
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta vrhovnog} \\ \text{menadžmenta poduzeća} \end{array} \right]
 \end{array}
 =
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta alternativa u} \\ \text{odnosu na cilj (12 vitkih alata)} \end{array} \right]
 \end{array}
 \quad (9.7)$$

Za dobivanje vektora prioriteta alternativa u odnosu na cilj – najpogodnijih vitkih alata za uslužna mikropoduzeća potrebno je izračunati vektor prioriteta vrhovnog menadžmenta poduzeća. Na taj način vrhovni menadžment poduzeća usporedbom čimbenika (potencijal smanjenja gubitaka, financijski čimbenik, organizacijski čimbenik) u parovima prema *Saatyjevoj skali* daje prioritet pojedinim čimbenicima. Postupak izračuna vektora prioriteta opisan je u poglavlju 8.1.3.1 i 8.1.3.2.

Množenjem matrice prioriteta (vektori prioriteta: prema pokazatelju uslužna mikropoduzeća (izraz 8.9), financijskog (izraz 9.2) čimbenika i organizacijskog (izraz 9.3) čimbenika) s vektorom prioriteta vrhovnog menadžmenta poduzeća dobiva se ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata za promatrano uslužno mikropoduzeće.

9.2.4. Model učinkovitoga upravljanja uslužnim malim, srednje velikim i velikim poduzećima

Uvrštenjem ukupnog vektora prioriteta za uslužna mala, srednje velika i velika poduzeća (izraz 8.7) vektora prioriteta prema kriteriju financijski čimbenik (izraz 9.2) i vektora prioriteta po kriteriju organizacijski čimbenik (izraz 9.3) u opći model učinkovitoga upravljanja poduzećem (izraz 9.4) dobiva se model učinkovitoga upravljanja uslužnim malim, srednje velikim i velikim poduzećima (izraz 9.8).

$$\begin{array}{l}
 \text{5 S} \\
 \text{Jidoka} \\
 \text{JIT} \\
 \text{Kaizen} \\
 \text{Kanban} \\
 \text{Kontinuirani tok} \\
 \text{Map. toka vrijed.} \\
 \text{Poka Yoke} \\
 \text{SMED} \\
 \text{Standard. rad} \\
 \text{Taktno vrijeme} \\
 \text{TPM}
 \end{array}
 \begin{array}{c}
 \text{izraz 8.11} \\
 \left[\begin{array}{c} 0,0741 \\ 0,0615 \\ 0,1143 \\ 0,1170 \\ 0,0742 \\ 0,0992 \\ 0,1020 \\ 0,0570 \\ 0,0509 \\ 0,1116 \\ 0,0529 \\ 0,0853 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.2} \\
 \left[\begin{array}{c} 0,1918 \\ 0,0290 \\ 0,0189 \\ 0,1918 \\ 0,0290 \\ 0,0204 \\ 0,0829 \\ 0,0428 \\ 0,0428 \\ 0,1149 \\ 0,1918 \\ 0,0441 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.3} \\
 \left[\begin{array}{c} 0,2357 \\ 0,0711 \\ 0,0191 \\ 0,1038 \\ 0,0268 \\ 0,0436 \\ 0,0436 \\ 0,1138 \\ 0,0404 \\ 0,0687 \\ 0,1947 \\ 0,0386 \end{array} \right]
 \end{array}
 \cdot
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta vrhovnog} \\ \text{menadžmenta poduzeća} \end{array} \right]
 \end{array}
 =
 \begin{array}{c}
 \left[\begin{array}{c} \text{Vektor prioriteta alternativa u} \\ \text{odnosu na cilj (12 vitkih alata)} \end{array} \right]
 \end{array}
 \quad (9.8)$$

Za dobivanje vektora prioriteta alternativa u odnosu na cilj – najpogodnijih vitkih alata za uslužna mala, srednje velika i velika poduzeća potrebno je izračunati vektor prioriteta vrhovnog menadžmenta poduzeća. Na taj način vrhovni menadžment poduzeća usporedbom čimbenika (potencijal smanjenja gubitaka, financijski čimbenik, organizacijski čimbenik) u parovima prema *Saatyjevoj skali* daje prioritet pojedinim čimbenicima. Postupak izračuna vektora prioriteta opisan je u poglavlju 8.1.3.1 i 8.1.3.2.

Množenjem matrice prioriteta (vektori prioriteta: prema pokazatelju uslužna mala, srednje velika i velika poduzeća (izraz 8.11), financijskog (izraz 9.2) čimbenika i organizacijskog (izraz 9.3) čimbenika) s vektorom prioriteta vrhovnog menadžmenta poduzeća dobiva se ukupni vektor prioriteta alternativa u odnosu na cilj iz kojeg slijedi rang lista alternativa – vitkih alata za promatrano uslužno malo, srednje veliko ili veliko poduzeće.

10. VERIFIKACIJA MODELA I OBRADA PRIMJERA IZ PRAKSE

Najprije su navedene osnovne informacije o poduzeću Elektro-Kontakt d.d.. Nakon toga detaljno je opisan izračun vektora prioriteta vrhovnog menadžmenta prema pojedinim čimbenicima vitkih alata (potencijal smanjenja gubitaka u poslovanju poduzeća, financijski čimbenik i organizacijski čimbenik). Zatim je opisan izračun vektora prioriteta alternativa u odnosu na cilj (izraz 9.6) – najpogodniji vitki alati za implementaciju u proizvodno veliko poduzeće (Elektro-Kontakt d.d.). Dobivena rang lista vitkih alata verificirana je na osnovi podataka i spoznaja dobivenih od voditelja odjela za kontinuirano poboljšanje (*lean* trenera) poduzeća Elektro-Kontakt d.d. u koje je implementirana vitka metodologija.

U drugom dijelu poglavlja na osnovu dobivene rang liste najpogodnijih vitkih alata za implementaciju u poduzeće Elektro-Kontakt d.d. obrađen je primjer iz prakse – iskorištavanje otpadne toplinske energije kompresora sa svrhom smanjenja potrošnje energenata i utjecaja na okoliš, odnosno smanjenje emisije štetnih plinova.

10.1. O poduzeću Elektro-Kontakt d.d.

Poduzeće Elektro-Kontakt d.d., Zagreb osnovano je 1926. godine. Tijekom vremena se razvilo u stabilnu i uspješnu tvrtku pa je danas vodeći hrvatski proizvođač elektroinstalacijskog materijala. Glavni proizvodni program čine elektroinstalacijski materijal i komponente za kućanske aparate, dok glavnu programsku orijentaciju čini suradnja s komplementarnim inozemnim tvrtkama. Elektro-Kontakt d.d. se 1992. godine organizira kao dioničko društvo s većinskim udjelom dugogodišnjeg poslovnog partnera, njemačke grupacije EGO. Danas Elektro-Kontakt d.d. zapošljava oko 850 radnika, s ukupnim prihodom od oko 70 milijuna EUR-a, od čega se više od 90 % ostvaruje izvozom. Svakog radnog dana na zapadno-europsko tržište izveze više od 150.000 proizvoda visoke kvalitete. [84]

Proizvodni program elektroinstalacijskog materijala čini više od 300 proizvoda. Sklopke, utičnice, utikači, prijenosne priključnice u više modernih dizajna, proizvedene prema IEC standardima, u skladu s njemačkom i francuskom normom, uspješno predstavljaju Elektro-Kontakt d.d. na domaćem i svjetskom tržištu. Grla, instalacijske cijevi i kutije, razdjelnici,

osigurači, automatski prekidači, mjerni ormarići, nadžbukni program IP20, te nadžbukni program za vlažne prostore kompletiraju asortiman elektroinstalacijskog materijala. [84]

Koristeći komparativne prednosti internacionalne suradnje Elektro-Kontakt d.d. dostigao je stupanj konkurentnosti koji mu omogućava zadovoljenje 35 % potreba svjetskog tržišta u pogledu regulacijskih uređaja za suvremene električne štednjake. Neprekidno ulaganje u tehničko-tehnološki razvoj, primjena suvremene mrežne organizacije, stalno obrazovanje kadrova, odnos prema kvaliteti usklađen s najnovijim ISO standardima, zaštita radnika, zaštita okoline i visok stupanj društvene odgovornosti važni su element poslovne politike koja se kontinuirano provodi i daje zapažene rezultate. Navedeni rezultati svrstavaju Elektro-Kontakt d.d. u grupu najboljih velikih poduzeća u Republici Hrvatskoj. [84]


10.2. Model učinkovitoga upravljanja

Poduzeće Elektro-Kontakt d.d. prema pokazateljima poduzeća veliko je proizvodno poduzeće (oko 850 zaposlenika). Kod odabira najpogodnijih vitkih alata za implementaciju u navedeno poduzeće primijenjen je izrađeni model učinkovitoga upravljanja proizvodnim malim, srednje velikim i velikim poduzećima (izraz 9.6).

Za izračun vektora prioriteta alternativa u odnosu na cilj – najpogodniji vitki alati za implementaciju u proizvodno veliko poduzeće (Elektro-Kontakt d.d.) prema izrazu 9.6 potrebno je poznavati i vektor prioriteta vrhovnog menadžmenta. Izračun navedenih vektora detaljno je opisan u onome što slijedi.

10.2.1. Vektor prioriteta vrhovnog menadžmenta

Provedenom usporedbom čimbenika (potencijal smanjenja gubitaka, financijski čimbenik, organizacijski čimbenik) u parovima prema *Saatyjevoj skali* vrhovni menadžment daje prioritet pojedinim čimbenicima (slika 10.1) na osnovi kojih se definira matrica usporedbe. Na primjeru poduzeća Elektro-Kontakt d.d. podaci za izradu matrice usporedbe dobiveni su od Rukovoditelja odjela proizvodnih sistema i CIP-a (kontinuiranog procesa poboljšanja) Jose Matasića.



Slika 10.1. Prikaz usporedbi na Saatyjevoj skali

Kod formiranja matrice usporedbe (tablica 10.1) potrebno se pridržavati pravila: "Ako se iznos usporedbe nalazi na lijevoj strani Saatyjeve skale, u matricu se upisuje isti taj iznos, a ako se iznos usporedbe nalazi na desnoj strani Saatyjeve skale, u matricu se upisuje recipročna vrijednost iznosa" (poglavlje 8.1.3.).

Tablica 10.1. Matrica usporedbe

	vitki alat	financijski čimbenik	organizacijski čimbenik
vitki alat	1	3	1/3
financijski čimbenik	1/3	1	1/4
organizacijski čimbenik	3	4	1

10.2.1.1. Množenje matrice usporedbe

Množenjem matrice usporedbe (tablica 10.1) dobiva se nova matrica (izraz 10.1):

$$\begin{bmatrix} 1 & 3 & 0,3333 \\ 0,3333 & 1 & 0,25 \\ 3 & 4 & 1 \end{bmatrix} \cdot \begin{bmatrix} 1 & 3 & 0,3333 \\ 0,3333 & 1 & 0,25 \\ 3 & 4 & 1 \end{bmatrix} = \begin{bmatrix} 3 & 7,3333 & 1,4166 \\ 1,4166 & 3 & 0,6111 \\ 7,3333 & 17 & 3 \end{bmatrix} \quad (10.1)$$

Tablica 10.2. Matrica usporedbe nakon prvog množenja

	vitki alat	financijski čimbenik	organizacijski čimbenik
vitki alat	3	7,3333	1,4166
financijski čimbenik	1,4166	3	0,6111
organizacijski čimbenik	7,3333	17	3

10.2.1.2. Određivanje 1. vektora prioriteta

Sumiranje redova matrice:

$$\begin{bmatrix} 3 & 7,3333 & 1,4166 \\ 1,4166 & 3 & 0,6111 \\ 7,3333 & 17 & 3 \end{bmatrix} = \begin{array}{r} 11,7500 \\ 5,0278 \\ 27,3333 \\ \hline 44,1111 \end{array} \quad (10.2)$$

Normalizacija sume redova:

$$\begin{bmatrix} 11,7500 / 44,1111 \\ 5,0278 / 44,1111 \\ 27,3333 / 44,1111 \end{bmatrix} \rightarrow \begin{bmatrix} 0,2664 \\ 0,1140 \\ 0,6196 \end{bmatrix} \quad (10.3)$$

1. vektor prioriteta

10.2.1.3. Množenje matrice usporedbe

Množenjem prethodne matrice usporedbe (tablica 10.2) dobiva se nova matrica (izraz 10.4):

$$\begin{bmatrix} 3 & 7,3333 & 1,4166 \\ 1,4166 & 3 & 0,6111 \\ 7,3333 & 17 & 3 \end{bmatrix} \cdot \begin{bmatrix} 3 & 7,3333 & 1,4166 \\ 1,4166 & 3 & 0,6111 \\ 7,3333 & 17 & 3 \end{bmatrix} = \begin{bmatrix} 29,7777 & 68,0833 & 12,9814 \\ 12,9814 & 29,7777 & 5,6736 \\ 68,0833 & 155,7777 & 29,7777 \end{bmatrix} \quad (10.4)$$

Tablica 10.3. Matrica usporedbe nakon drugog množenja

	vitki alat	financijski čimbenik	organizacijski čimbenik
vitki alat	29,7777	68,0833	12,9814
financijski čimbenik	12,9814	29,7777	5,6736
organizacijski čimbenik	68,0833	155,7777	29,7777

10.2.1.4. Određivanje 2. vektora prioriteta

Sumiranje redova matrice:

$$\begin{bmatrix} 29,7777 & 68,0833 & 12,9814 \\ 12,9814 & 29,7777 & 5,6736 \\ 68,0833 & 155,7777 & 29,7777 \end{bmatrix} = \begin{array}{r} 110,8426 \\ 48,4328 \\ \hline 253,6389 \\ 412,9144 \end{array} \quad (10.5)$$

Normalizacija sume redova:

$$\begin{bmatrix} 110,8426 / 412,9144 \\ 48,4328 / 412,9144 \\ 253,6389 / 412,9144 \end{bmatrix} \rightarrow \begin{bmatrix} 0,2684 \\ 0,1173 \\ 0,6143 \end{bmatrix} \quad (10.6)$$

2. vektor prioriteta

Izračunavanje razlike vektora prioriteta:

$$\begin{array}{ccc} \begin{bmatrix} 0,2664 \\ 0,1140 \\ 0,6196 \end{bmatrix} & - & \begin{bmatrix} 0,2684 \\ 0,1173 \\ 0,6143 \end{bmatrix} = \begin{bmatrix} -0,0021 \\ -0,0033 \\ 0,0054 \end{bmatrix} \\ \text{1. vektor} & \text{2. vektor} & \text{vektor razlika} \end{array} \quad (10.7)$$

Izračunate razlike vektora prioriteta male su pa nije potrebno daljnje izračunavanje vektora prioriteta.

10.2.1.5. Izračunavanje konzistentnosti

Budući da je rađena matrica usporedbe prema *Saatyjevoj skali*, za izračunati vektor prioriteta provjerena je njegova konzistentnost prema postupku opisanom u poglavlju 8.1.3.2.

$$\begin{array}{ccc} \left[\begin{array}{ccc} 1 & 3 & 0,3333 \\ 0,3333 & 1 & 0,25 \\ 3 & 4 & 1 \end{array} \right] & \left[\begin{array}{c} 0,2684 \\ 0,1173 \\ 0,6143 \end{array} \right] & \\ \hline 4,3333 & 8,0000 & 1,5833 & \begin{array}{l} \text{2. vektor} \\ \text{prioriteta} \end{array} \end{array} \quad (10.8)$$

matrica usporedbe

Izračun maksimalne vrijednosti matrice λ_{\max} prema izrazu (8.1)

$$\lambda_{\max} = 4,3333 \cdot 0,2684 + 8,0000 \cdot 0,1173 + 1,5833 \cdot 0,6143 = 3,0742$$

Izračun indeksa konzistentnosti CI prema izrazu (8.2)

$$CI = \frac{3,0742 - 3}{3 - 1} = 0,0371$$

Izračun omjera konzistentnosti CR prema izrazu (8.3)

$$CR = \frac{0,0371}{0,58} = 0,0640$$

Za izračunati omjer konzistentnosti ($CR = 0,0640$) može se zaključiti da su procjene relativnih važnosti alternativa prihvatljive, odnosno konzistentne ($CR \leq 0,10$).


10.2.2. Vektor prioriteta vitkih alata za proizvodno veliko poduzeće Elektro-Kontakt d.d.

Množenjem matrice prioriteta (vektori prioriteta: prema pokazatelju proizvodna mala, srednje velika i velika poduzeća (izraz 8.7), financijskog (izraz 9.2) čimbenika i organizacijskog

(izraz 9.3) čimbenika) s vektorom prioriteta vrhovnog menadžmenta poduzeća Elektro-Kontakt d.d. (izraz 10.6) dobiva se ukupni vektor prioriteta alternativa u odnosu na cilj (izraz 10.9) iz kojeg slijedi rang lista alternativa – vitkih alata za promatrano proizvodno veliko poduzeće (Elektro-Kontakt d.d.).

$$\begin{array}{l}
 \text{5 S} \\
 \text{Jidoka} \\
 \text{JIT} \\
 \text{Kaizen} \\
 \text{Kanban} \\
 \text{Kontinuirani tok} \\
 \text{Map. toka vrijed.} \\
 \text{Poka Yoke} \\
 \text{SMED} \\
 \text{Standard. rad} \\
 \text{Taktno vrijeme} \\
 \text{TPM}
 \end{array}
 \begin{array}{c}
 \text{izraz 8.7} \\
 \left[\begin{array}{c} 0,0732 \\ 0,0627 \\ 0,1166 \\ 0,1122 \\ 0,0692 \\ 0,1036 \\ 0,0986 \\ 0,0580 \\ 0,0517 \\ 0,1091 \\ 0,0536 \\ 0,0916 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.2} \\
 \left[\begin{array}{c} 0,1918 \\ 0,0290 \\ 0,0189 \\ 0,1918 \\ 0,0290 \\ 0,0204 \\ 0,0829 \\ 0,0428 \\ 0,0428 \\ 0,1149 \\ 0,1918 \\ 0,0441 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \text{izraz 9.3} \\
 \left[\begin{array}{c} 0,2357 \\ 0,0711 \\ 0,0191 \\ 0,1038 \\ 0,0268 \\ 0,0436 \\ 0,0436 \\ 0,1138 \\ 0,0404 \\ 0,0687 \\ 0,1947 \\ 0,0386 \end{array} \right]
 \end{array}
 \cdot
 \begin{array}{c}
 \text{izraz 10.6} \\
 \left[\begin{array}{c} 0,2684 \\ 0,1173 \\ 0,6143 \end{array} \right]
 \end{array}
 =
 \begin{array}{c}
 \left[\begin{array}{c} 0,1869 \\ 0,0639 \\ 0,0452 \\ 0,1164 \\ 0,0384 \\ 0,0570 \\ 0,0630 \\ 0,0905 \\ 0,0437 \\ 0,0850 \\ 0,1565 \\ 0,0535 \end{array} \right]
 \end{array}
 \quad (10.9)$$

Na osnovi ukupnog vektora prioriteta alternativa u odnosu na cilj (izraz 10.9) na slici 10.2 prikazan je *Pareto dijagram* vitkih alata za proizvodno veliko poduzeće (Elektro-Kontakt d.d.).



Slika 10.2. Pareto dijagram vitkih alata za proizvodno veliko poduzeće (Elektro-Kontakt d.d.).

Iz izraza 10.6 vidi se da je najveći prioritet unutar poduzeća Elektro-Kontakt d.d. dodijeljen organizacijskom čimbeniku, a najmanji financijskom čimbeniku. Dobivenim *Pareto dijagramom* vidi se da je najpogodniji alat za implementaciju 5 S, zatim slijedi taktno vrijeme, Kaizen i dr.

10.2.3. Verifikacija modela

Verifikacija modela učinkovitoga upravljanja poduzećem rađena je na primjeru velikog vitkog (e. *lean*) proizvodnog poduzeća Elektro-Kontakt d.d. (dio njemačke grupacije EGO). Poduzeća unutar grupacije EGO sastavni su dio vitkog programa "EVEREST" koji obuhvaća tri područja: vitku proizvodnju (e. *lean production*), vitki razvoj proizvoda (e. *lean development*) i vitku administraciju (e. *lean administration*). Za implementaciju i razvoj programa "EVEREST" u poduzeće Elektro-Kontakt d.d. zadužena su tri obučena *lean* trenera te oko 30 djelatnika po različitim odjelima i radnim mjestima unutar poduzeća.

Na slici 8.9 (poglavlje 8.3) prikazana je rang lista najpogodnijih vitkih alata za smanjenje gubitaka u poslovanju hrvatskih proizvodnih velikih poduzeća. Uzevši u obzir financijske i organizacijske čimbenike implementacije vitkih alata u poduzeće Elektro-Kontakt d.d., preko vektora prioriteta vrhovnog menadžmenta poduzeća (izraz 10.6) dobivena je rang lista najpogodnijih vitkih alata za implementaciju u navedeno poduzeće, prikazano na slici 10.2.

Dobivena rang lista (*Pareto dijagram*) vitkih alata za poduzeće Elektro-Kontakt d.d. (slika 10.2) raspravljena je s voditeljem odjela za kontinuirano poboljšanje, a ujedno i *lean* trenerom poduzeća Elektro-Kontakt d.d., Zagreb. Izrađenim modelom došlo se do zaključka da je vitki alat 5 S najpogodniji za implementaciju, što je u potpunosti ispravno i potvrđeno u praksi. Upravo 5 S prvi je vitki alat s kojim je započela implementacija vitkog programa "EVEREST" u poduzeće Elektro-Kontakt d.d., odnosno on predstavlja bazu za implementaciju ostalih vitkih alata. Na drugom mjestu dobivene rang liste nalazi se taktno vrijeme koje prema spoznajama *lean* trenera ide u sklopu vitkih alata kontinuirani tok i JIT. Budući da model uključuje financijske i organizacijske čimbenike implementacije vitkih alata, logično je očekivati da se taktno vrijeme nalazi na samom vrhu rang liste jer je vektorom prioriteta vrhovnog menadžmenta (izraz 10.6) dodijeljen visoki prioritet organizacijskom čimbeniku. Raspravljen je i poredak ostalih vitkih alata, pa se može reći da je u skladu s

primjenom u praksi. Važno je naglasiti da se u poduzeće ne implementira vitki alat po alat, nego više vitkih alata istovremeno jer su međusobno povezani.

Kao što je navedeno, uz vitki alat 5 S implementacija programa "EVEREST" započela je i s alatom mapiranje toka vrijednosti, čime su zatim uključeni i svi vitki alati navedeni u modelu učinkovitoga upravljanja.

Programom "EVEREST" u poduzeću Elektro-Kontakt d.d. postignuti su zavidni rezultati, a to najbolje pokazuju izvješća provedenih internih audita. Interni auditi provode se u sedam odjela poduzeća (tri odjela montaže, odjelu izrade plastičnih dijelova, odjelu izrade metalnih dijelova, odjelu alatnice i odjelu održavanja) prema osam pokazatelja uspješnosti:

- spremnost na promjene
- organizacija kontinuiranog poboljšanja (kako su organizirani za provođenje projekta "EVEREST")
- vizija procesa (ciljevi, standardi i dr.)
- kvalifikacije (zaposlenika, trenera i sl.)
- komunikacija (sustav komunikacija i sl.)
- metode i alati (5 S, neposredan rad sa zaposlenicima, tok vrijednosti i dr.)
- plan radionica i projekata (proces, aktivni projekti, održivost i dr.)
- ključni pokazatelji (sustava, bazne značajke, OEE – ukupna učinkovitost opreme i dr.).

Iz izvješća internih audita provedenih u 2011. godini sveukupan postotak pokazatelja uspješnosti iznosio je 29 %, a u 2015. godini 67 %. Prema informacijama dobivenima od voditelja odjela za kontinuirano poboljšanje najveća poboljšanja postignuta su u odjelu izrade plastičnih dijelova. Uzrok tomu svakako su zaposlenici koji, prema njegovim riječima, "upijaju, provode i predlažu poboljšanja".


U proizvodnom poduzeću koje radi prema vitkim načelima, očekuje se od svih zaposlenika da aktivno rade na postizanju dodatnih poboljšanja procesa proizvodnje radi kontinuiranog poboljšanja poslovanja uklanjanjem gubitaka iz proizvodnog procesa. To su ujedno i glavne značajke vitkog alata Kaizen, koji se nalazi na trećem mjestu rang liste najpogodnijih vitkih alata za implementaciju u poduzeće Elektro-Kontakt d.d. (slika 10.2). Naravno, uz vitku proizvodnu strategiju provodi se i zelena proizvodna strategija, kao dio ukupne strategije smanjenja potrošnje energenata i štetnog utjecaja na okoliš. Važnost kvalitetnih i odgovornih

zaposlenika najbolje je prikazana na primjeru iskorištavanja otpadne toplinske energije s kompresora izvedenog u poduzeću Elektro-Kontakt d.d., koje je opisano u onome što slijedi.

10.3. Konkretni podaci primjene vitke i zelene proizvodnje

Za potrebe proizvodnog procesa poduzeća Elektro-Kontakt d.d. upotrebljavaju se velike količine komprimiranog zraka proizvedene u kompresorskim stanicama poduzeća. Kompresori za sustav hlađenja ulja koriste zrak koji pritom zagrijevaju, ovisno o opterećenju, na temperaturu od 40 – 60 °C, a zrak se potom ispušta kanalima u atmosferu. [85] Pod vodstvom rukovoditeljice odjela Održavanja i upravljanja okolišem Jasne Hlupić inicirana je analiza utvrđivanja potencijala uštede toplinske energije iskorištavanjem otpadne toplinske energije kompresora, a ta je analiza izrađena u suradnji s vanjskim stručnim suradnicima. U nastavku su prikazani konkretni podaci koji se postižu ispravnim pristupom vitkoj proizvodnji, odnosno primjenom alata i tehnika vitke i zelene proizvodnje.

Predmet analize kompresorska je stanica koja se nalazi u objektu F (slika 10.3), gdje su instalirani kompresori K1 (45 kW električne snage), K2 (45 kW električne snage), K3 (90 kW električne snage) i K4 (132 kW električne snage) proizvođača Atlas Copco. [85]



Slika 10.3. Dispozicija zgrada kompleksa Elektro-Kontakt d.d. [86]

10.3.1. Potencijal za postizanje ušteda

S obzirom na veliku količinu odbačene toplinske energije u obliku zagrijanog zraka, izrađen je izračun ušteda toplinske energije koja obuhvaća ugradnju uređaja za povrat toplinske energije na kompresore K3 (90 kW električne snage) i K4 (132 kW električne snage) te iskorištavanje dobivene toplinske energije za zagrijavanje potrošne tople vode (PTV) u cjelogodišnjem razdoblju. U zimskom periodu, u sezoni grijanja, višak topline upotrijebit će se za predgrijavanje radnog medija sustava radijatorskog kruga grijanja. [85]

Tablica 10.4. Instalirani kompresori [85]

Redni broj	Model kompresora	Snaga (kW)	Radni sati (ukupni) 11.4.2014.	Radni sati opterećenja 11.4.2014.	% rada pod opterećenjem	Radni sati godišnje (h)	Radni sati opterećenja godišnje (h)	Radni sati bez opterećenja godišnje (h)	Energija godišnje = (3) · (8) + (3) · (9) · 0,2 (kWh) za VSD *60 %
1	2	3	4	5	6	7	8	9	10
1	GA45-10	45	69.398	60.655	87,40	1.777	1.553	224	71.921
2	GA45-10	45	81.034	60.042	74,09	2.795	2.071	724	99.702
3	GA90FF-7,5	90	42.363	40.239	94,99	4.861	4.618	244	419.975
4	GA132FF-7,5	132	16.179	15.270	94,38	5.527	5.216	311	696.757
Ukupno svi kompresori									1.288.355
Ukupno 1 i 2									171.623
Ukupno 3 i 4									1.116.732

* VSD – promjenljiv broj okretaja (e. *Variable Speed Drive*)

Iz tablice 10.4 vidi se da su kompresori K1 i K2 znatno manjih snaga (45 kW električne snage), pa zato nisu uzeti u obzir u daljnjoj analizi.

10.3.2. Dnevne potrebe energije za grijanje potrošne tople vode (PTV-a)

Navedeni podaci preuzeti su iz sustava automatskog upravljanja toplinskom stanicom, iz dostupne projektne dokumentacije te iz mjerenja bitnih termotehničkih veličina koje su

kasnije korištene u izračunu. Kod proračuna potrebne topline za zagrijavanje vode uzeta je u obzir energija potrebna za zagrijavanje vode (izraz 10.1) i energija za recirkulaciju koja je izračunata na bazi razlike temperature polaznog i povratnog voda te protoka kroz cirkulacijsku pumpu. [85]

$$Q = m \cdot c \cdot (T_2 - T_1) \quad (10.1)$$

gdje je: Q [kWh] – toplinska energija, m [kg] – masa, c [J/kgK] – specifični toplinski kapacitet, $T_{1,2}$ [K] – termodinamička temperatura.

Period promatranja podijeljen je na ljetni (3.800 sati) i zimski (2.680 sati) gdje se uzimalo u obzir broj radnih sati poduzeća (izuzev recirkulacije koja radi 24 h/dan). Brojčani podaci prikazani su u tablici 10.5.

Tablica 10.5. Energija potrebna za zagrijavanje PTV-a [85]

Zagrijavanje vode	
Dnevna potrošnja vode	6 m ³
Temperatura vode na ulazu (prosjek ljeto/zima)	15 °C
Temperatura vode u spremniku	50 °C
Potrebna energija	244,24 kWh / dan
Recirkulacija vode	
Temperatura vode u povratu prije izmjenjivača (kondenzator i parni izmjenjivač; miješanje sa svježom vodom)	35 °C
Protok u recirkulaciji	3 m ³ /h
Recirkulacija	52,34 kW
Dnevna potrebna energija za grijanje PTV i recirkulaciju (recirkulacija radi 24 h)	1500,34 kWh / dan
Energija za PTV	
Grijanje isključeno	237.554 kWh / god
Grijanje uključeno	167.538 kWh / god
Ukupno	405.092 kWh / god

10.3.3. Energija dobivena iz kompresora K3 i K4 na godišnjoj razini

U tablici 10.6 prikazana je električna snaga kompresora, snaga toplinskog izmjenjivača i efektivna snaga izmjenjivača kompresora preko kojih se odvija rekuperacija toplinske energije s kompresora. Podaci su prikazani prema specifikacijama proizvođača Atlas Copco.

Tablica 10.6. Snage kompresora K3 i K4 [85]

	El. snaga (kW)	Snaga topl. izmj. (kW)	Efektivna snaga. izmj. (kW)
Kompresor 3	90	67	47
Kompresor 4	132	99	70
Ukupno	222	166	117

Iz navedenih podataka, ukupno instalirana toplinska snaga izmjenjivača iznosi 166 kW, a efektivna snaga izmjenjivača 117 kW. Kako bi se ispitala toplinska raspoloživost rekuperacije topline, cjelokupna godina podijeljena je na ljetni i zimski period. Na osnovi tvorničkih podataka o efektivnoj snazi na izmjenjivaču i režimima rada kompresora izračunata je energija koju je moguće dobiti iz rekuperacije. Osnovni podaci prikazani su u tablici 10.7.

Tablica 10.7. Snage izmjenjivača, radni sati kompresora i toplinska energija iz kompresora

Snaga izmjenjivača	
Ukupna instalirana snaga izmjenjivača	166 kW
Ukupna efektivna snaga izmjenjivača	117 kW
Radni sati kompresora *	
Ljetna sezona *	3.064 h
Zimska sezona *	2.130 h
Ukupno *	5.194 h / god
Toplinska energija iz kompresora	
Grijanje isključeno	358.542 kWh / god
Grijanje uključeno	249.156 kWh / god
Ukupno	607.698 kWh / god

* Prosječan broj radnih sati kompresora podijeljen je na ljetni i zimski period prema ključu omjera broja radnih sati poduzeća; ljetni period 3.800 h i zimski period 2.680 h (0,586 : 0,414)

10.3.4. Moguće iskorištavanje otpadne topline za zagrijavanje PTV-a i predgrijavanje za sustav radijatorskog kruga grijanja

U tablici 10.8 prikazana je ukupna energija raspoloživa s rekuperacije kompresora te energija koju je moguće iskoristiti za zagrijavanje PTV-a, kao i energija koja je dostatna u zimskom periodu i koja će se preusmjeriti u sustav grijanja radijatorima. Ukupna očekivana pokrivenost sustava PTV-a iz rekuperacije topline iznosi oko 97%. [85]

Tablica 10.8. Energija iz kompresora [85]

	Ljetni period	Zimski period	Ukupno
Energija potrebna za zagrijavanje PTV (kWh / god)	237.554	167.538	405.092
Iskoristiva energija iz kompresora za PTV	237.554	167.538	405.092
Ukupna energija dobivena iz kompresora (kWh / god)	358.542	249.156	607.698
Udio energije kompresora u energiji za zagrijavanje PTV-a (kWh) – ušteda*	230.427	162.512	392.939
Udio energije pare za zagrijavanje PTV-a (kWh)	7.127	5.026	12.153
Udio energije kompresora u energiji za zagrijavanje PTV-a (%) - ušteda*	97,0 %	97,0 %	97,0 %
Udio energije pare za zagrijavanje PTV-a (%)	3,0 %	3,0 %	3,0 %
Višak energije iz kompresora iskoristiv za grijanje (kWh) - ušteda	0	86.644	86.644

* Ako je energija koju dobivamo iz kompresora veća od potrebne energije za zagrijavanje PTV-a, udio energije kompresora u ukupnoj energiji potrebnoj za zagrijavanje PTV-a procjenjuje se na razini 97 % zbog eventualne upotrebe pare pri vršnim opterećenjima.

10.3.5. Izračun financijskih ušteda i smanjenja emisije CO₂

Prema podacima iz tablice 10.8, godišnje je moguće preuzeti 479.583 kWh otpadne toplinske energije s kompresora. Za navedeni iznos energije umanjuje se potrošnja pare koja se koristi za zagrijavanje potrošne tople vode i radnog medija sustava grijanja. Para tlaka 6 bara, temperature 160 °C dovodi se magistralnim parovodom DN 150 iz gradske mreže (HEP Toplinarstvo d.o.o.) u toplinsku stanicu kompleksa Elektro-Kontakt d.d.. [85, 86]

U tablici 10.9 prikazane su financijske uštede ako se umjesto pare upotrijebi otpadna toplina s kompresora. Navedene cijene izražene su bez poreza na dodanu vrijednost (PDV-a). [86]

Tablica 10.9. Financijske uštede na toplinskoj energiji [86]

Energent	Potrošnja (kWh)	Jedinična cijena (kn / kWh)	Trošak (kn)
Toplinska energija	479.583	0,48	230.200

Emisije CO₂ za toplinsku energiju izračunate su prema koeficijentima danima u Metodologiji o provođenju energetskih pregleda građevina, lipanj 2014. godine, koje se računaju sa specifičnim koeficijentom 0,257 kg CO₂ / kWh. [86]

$$EM = AD \cdot EF \quad (10.2)$$

gdje je: EM [kg /god] – emisije CO₂, AD [kWh / god] – količina potrošene toplinske energije, EF [kg CO₂ / kWh] – specifični koeficijent emisije CO₂ za toplinsku energiju.

$$\begin{aligned} EM &= 479.583 \cdot 0,257 \\ &= 123.252 \text{ kg}_{(\text{CO}_2)}/\text{god} \end{aligned}$$

Izvedbom navedene mjere moguće je ostvariti financijske uštede od 230.200 kn, bez PDV-a, na godišnjoj razini, uz istovremeno smanjenje emisije CO₂ od približno 123.250 kg godišnje.

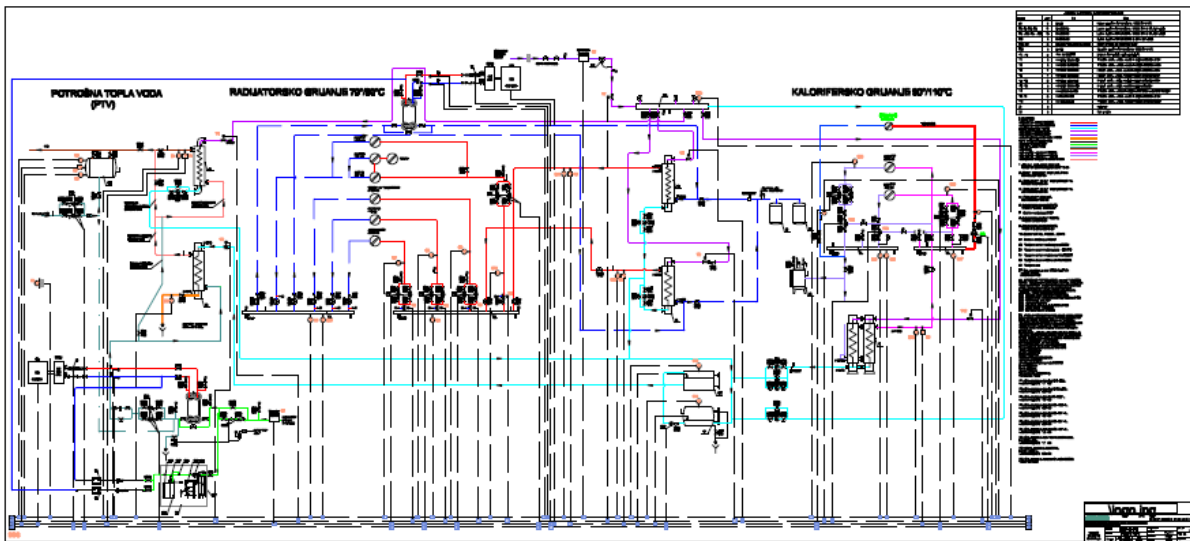
10.3.6. Provedba predloženih mjera

Izrađena analiza potencijala uštede toplinske energije iskorištavanjem otpadne topline kompresora K3 i K4 prezentirana je Upravi poduzeća Elektro-Kontakt d.d., koja je odobrila realizaciju projekta.

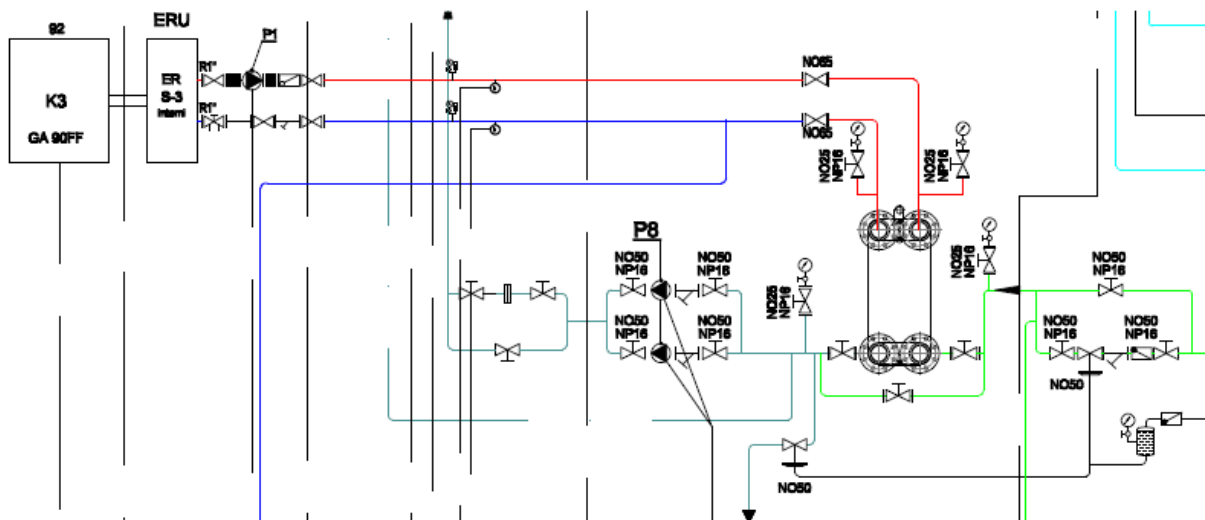
Za navedeni projekt na Javnom natječaju za sufinanciranje projekata energetske učinkovitosti u industriji od strane Fonda za zaštitu okoliša i energetske učinkovitost ostvarena je subvencija u iznosu od 40 % opravdanih troškova. Navedeni projekt "Projekt energetske učinkovitosti primjenom mjere povrata toplinske energije s kompresora" na Javnom natječaju

ocijenjen je od strane Fonda za zaštitu okoliša i energetska učinkovitost kao najbolji od 18 projekta koji su zadovoljili uvjete natječaja.[87]

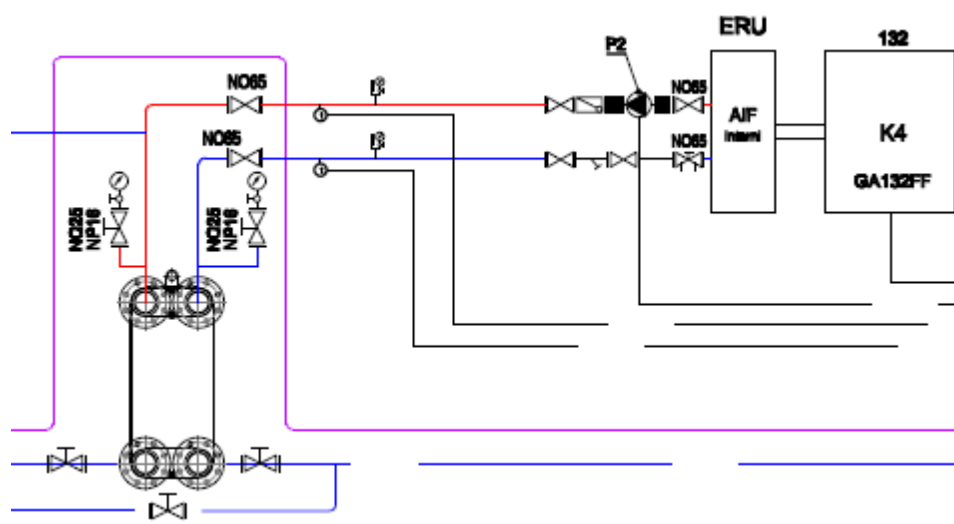
Shematski prikaz izvedenog stanja termotehničkog sustava poduzeća Elektro-Kontakt d.d. donosi se na slici 10.4. Radi preglednosti, na slici 10.5 prikazan je detalj shematskog prikaza izvedenog stanja pripreme potrošne tople vode, a na slici 10.6 prikazan je detalj izvedenog stanja predgrijavanja ogrjevnog medija sustava radijatorskog grijanja.



Slika 10.4. Shematski prikaz izvedenog stanja [88]



Slika 10.5. Detalj shematskog prikaza izvedenog stanja pripreme potrošne tople vode [88]



Slika 10.6. Detalj shematskog prikaza izvedenog stanja predgrijavanja ogrjevnog medija sustava radijatorskog grijanja [88]

11. ANALIZA REZULTATA

11.1. Analiza provedenog istraživanja o upravljanju poduzećima u RH

Zaposlenici hrvatskih poduzeća nisu skloni sudjelovati u znanstvenom istraživanju pa čak ni onda ako je istraživanje vezano uz učinkovito upravljanje njihovim poduzećem. O tome najbolje govori podatak da je odaziv sudionika na istraživanje putem ankete s kojima niste ostvarili prethodnu suradnju samo 3,6 %. Zbog slabog odaziva sudionika istraživanja, u tri mjeseca, prikupljeno je 296 anketa, od čega njih 16 nije uzeto u obzir za daljnje analize jer na više pitanja (od njih sedam) nisu dani odgovori.

Iz klasifikacije prikupljenih podataka vidi se da su provedenom anketom najviše obuhvaćena mikropoduzeća (manje od 10 zaposlenih osoba) s 35,2 % ukupnog broja anketiranih poduzeća i djelatnosti industrije (područja: B, C, D, E prema *Nacionalnoj klasifikaciji djelatnosti*) s udjelom od 43,2 %. Najveći broj sudionika istraživanja (60,4 %) pripada rukovodećem kadru poduzeća (vrhovni menadžment, srednji menadžment i prva razina menadžmenta).

Analizom grupe pitanja za testiranje razumijevanja vitke filozofije (anketna pitanja: 1., 2. i 3.) došlo se do zaključka da velik broj sudionika istraživanja ne prepoznaje prave vrijednosti, prednosti i način vitkog načina razmišljanja. U literaturi [11, 75, 10, 12] navodi se podrška i uključenost menadžmenta kao jedna od glavnih pretpostavki za uspješnu provedbu učinkovitoga upravljanja, odnosno vitke filozofije, dok svega oko 12 % ispitanika hrvatskih poduzeća pridaje tomu važnost. Također vrlo mali broj ispitanika, njih oko 33 %, smatra da je učinkovito upravljanje način kreiranja novog načina rada i poslovanja. Jednako se tako došlo do spoznaje da su razlozi investiranja u povećanje učinkovitosti poslovanja u hrvatskim poduzećima u potpunoj suprotnosti (gotovo inverzni) u odnosu na iste razloge kod anketiranih vitkih poduzeća obrađenih u literaturi [11].

S pomoću pitanja o komunikaciji kod provedbe projekata (anketna pitanja: 4. i 5.) saznalo se da oko 55 % anketiranih poduzeća ovisi o svojim dobavljačima. Osim uobičajenih načina komunikacije preko interneta i/ili telefona, samo približno 32 % njih međusobno komunicira s pomoću nekog posebnog programskog alata (mrežnog programa) koji svakako predstavlja

potencijal za poboljšanje komunikacije između poslovnih partnera i pridonosi povećanju učinkovitosti poduzeća.

Na pitanje o primjeni alata i tehnika vitke metodologije (anketno pitanje: 6.) velik broj sudionika istraživanja za veći broj ponuđenih alata nije navelo primjenu u poduzeću u kojem su zaposleni, najvjerojatnije zato što im nije poznata vitka terminologija. Na osnovu dobivenih odgovora može se reći da se u hrvatskim poduzećima, kako bi postala što učinkovitija, najčešće primjenjuju alati: tijek proizvodnje / usluge, 5S, mapiranje procesa (s rasponom vrijednosti od 75 % do 78 %). Alati poput: vrijeme obrade i standardizacija, SMED i KANBAN, koji se u vitkim poduzećima primjenjuju u visokim postocima (od 84 % do 92 %) [11], u anketiranim hrvatskim poduzećima primjenjuju se u znatno nižim postocima – s primjenom od približno 40 %.

Prema sudionicima istraživanja, za gotovo svaku od osam navedenih vrsta gubitaka u poslovanju poduzeća (anketno pitanje: 7.) postoji znatan potencijal za smanjenje tog gubitka u poduzeću. Ovi gubici primjenom odgovarajućeg alata vitke metodologije mogu se smanjiti, čime poduzeće postaje učinkovitije i samim time konkurentnije.

Iz testova proporcija uzoraka (tablica 6.8, 6.9 i 6.10) i testova frekvencije uzoraka (tablica 6.11 i 6.12) na anketama provedenima u hrvatskim poduzećima i inozemnim vitkim poduzećima, od strane drugih autora, vidi se da postoji bitna razlika u razmišljanjima sudionika istraživanja, pa je potrebno uložiti mnogo truda i energije kako bi i hrvatska poduzeća poprimila značajke vitkih poduzeća.

11.2. Analiza provedenih istraživanja o važnosti utjecaja pokazatelja poduzeća

Provedenim analizama važnosti utjecaja pokazatelja poduzeća (veličina poduzeća, djelatnost poduzeća i radno mjesto sudionika istraživanja) na podacima prikupljenima anketom o upravljanju poduzećima u RH došlo se do sljedećih spoznaja:

- odgovori sudionika istraživanja o primjeni alata i tehnika vitke metodologije u hrvatskim poduzećima statistički se znatno razlikuju samo prema djelatnosti poduzeća (proizvodna, uslužna).
- odgovori sudionika istraživanja o potencijalu smanjenja gubitaka u poslovanju hrvatskih poduzeća statistički se znatno razlikuju prema djelatnosti poduzeća (proizvodna, uslužna) i prema veličini poduzeća (mikropoduzeća, mala poduzeća, srednje velika poduzeća i velika poduzeća). Provedenom analizom prema veličini poduzeća došlo se do zaključka da je dovoljno razmatrati samo dvije grupe poduzeća za koje postoje znatne razlike: mikropoduzeća i ostala poduzeća (mala poduzeća, srednje velika poduzeća i velika poduzeća).

Na temelju onoga što je prethodno navedeno došlo se do zaključka da je dovoljno razmatrati prikupljene podatke prema pokazateljima poduzeća:

- djelatnost poduzeća – proizvodna i uslužna te
- veličini poduzeća – mikropoduzeća i ostala poduzeća (mala poduzeća, srednje velika poduzeća i velika poduzeća).

11.3. Analiza evaluacije vitkih alata

Provedenom evaluacijom vitkih alata prema pokazateljima poduzeća, iz podataka o potencijalima smanjenja gubitaka u poslovanju poduzeća prikupljenih anketom te primjenom AHP metode dobiveni su *Pareto dijagrami* (rang liste) najpogodnijih vitkih alata (slika 8.7, 8.9, 8.11, 8.13).

U tablici 11.1 dan je i tablični prikaz najpogodnijih vitkih alata (rang liste) prema pokazateljima poduzeća. Vitki alati u tablici navedeni su od najpogodnijega na niže. Analizom dobivenih rang listi vidi se da su neovisno o pokazateljima poduzeća, najpogodniji vitki alati (među prvih 6) ujedno i temeljni alati Toyotina proizvodnog sustava – TPS, iz kojega je razvijena vitka proizvodnja. Na osnovi provedenih analiza zaključuje se da su najpogodniji vitki alati, ovisno o pokazateljima poduzeća, JIT ili Kaizen. Od analiziranih 12 vitkih alata, za sve pokazatelje poduzeća, najmanji utjecaj na smanjenje gubitka u poslovanju poduzeća imaju taktno vrijeme i SMED. Također se vidi da se redoslijed vitkih alata za

mikropoduzeća i ostala (mala, srednje velika i velika) poduzeća unutar iste djelatnosti poduzeća (proizvodna ili uslužna) znatno razlikuje.

Provedenim analizama došlo se do zanimljivog podatka, a to je da je redoslijed vitkih alata za pokazatelje poduzeća proizvodna ostala (mala, srednje velika i velika) poduzeća i uslužna mikropoduzeća gotovo isti – u redoslijedu su vitki alati 5 S i Kanban zamijenili mjesta – 6. i 7. mjesto rang liste (tablica 11.1).

Tablica 11.1. Rang liste vitkih alata prema pokazateljima poduzeća

	proizvodna		uslužna	
	mikropoduzeća	ostala (mala, srednje velika i velika poduzeća)	mikropoduzeća	ostala (mala, srednje velika i velika poduzeća)
1	JIT	JIT	JIT	Kaizen
2	Kaizen	Kaizen	Kaizen	JIT
3	Kontinuirani tok	Standardizirani rad	Standardizirani rad	Standardizirani rad
4	Mapiranje toka vrijednosti	Kontinuirani tok	Kontinuirani tok	Mapiranje toka vrijednosti
5	TPM	Mapiranje toka vrijednosti	Mapiranje toka vrijednosti	Kontinuirani tok
6	Standardizirani rad	TPM	TPM	TPM
7	Kanban	5 S	Kanban	Kanban
8	5 S	Kanban	5 S	5 S
9	Jidoka	Jidoka	Jidoka	Jidoka
10	Poka Yoke	Poka Yoke	Poka Yoke	Poka Yoke
11	Taktno vrijeme	Taktno vrijeme	Taktno vrijeme	Taktno vrijeme
12	SMED	SMED	SMED	SMED

11.4. Analiza modela učinkovitoga upravljanja poduzećima

Na odabir koji je od vitkih alata s rang liste najpogodnijih prema pokazateljima poduzeća, prikazanih u tablici 11.1, optimalan izbor za smanjenje gubitaka u poslovanju poduzeća svakako imaju utjecaj i čimbenici poput troška i potrebnog vremena implementacije, potrebne organizacijske promjene u poduzeću i dr.

Na osnovi spoznaja drugih autora [71, 72], kao najvažniji čimbenici za odabir vitkih alata prilikom implementacije u neko poduzeće razmatrani su: potencijal smanjenja gubitaka u poslovanju poduzeća, financijski čimbenici (cijena implementacije) i organizacijski čimbenici (organizacijske promjene za uspješnu implementaciju – složenost implementacije).

Navedeni čimbenici kod izrade modela učinkovitoga upravljanja hrvatskim poduzećima uzeti su u obzir preko vektora prioriteta vrhovnog menadžmenta, pa je izrađen opći model učinkovitoga upravljanja poduzećem (izraz 9.4), na osnovi kojega su izrađeni modeli učinkovitoga upravljanja za svaki od pokazatelja poduzeća: proizvodna mikropoduzeća (izraz 9.5), proizvodna ostala (mala, srednje velika i velika) poduzeća (izraz 9.6), uslužna mikropoduzeća (izraz 9.7), uslužna ostala (mala, srednje velika i velika) poduzeća (izraz 9.8).

11.5. Smjerovi budućih istraživanja

U ovom radu izrađeni su modeli učinkovitoga upravljanja prema pokazateljima poduzeća na osnovi podataka prikupljenih anketom te empirijskih spoznaja stručnjaka na osnovi kojih su izračunati vektori prioriteta prema alternativama (12 vitkih alata) vezani uz financijske i organizacijske čimbenike. Navedeni vektori prioriteta financijskih i organizacijskih čimbenika zatim su jednoznačno primijenjeni na sva četiri modela učinkovitoga upravljanja poduzećima (prema pokazateljima poduzeća). U daljnjim istraživanjima trebalo bi ustanoviti postoje li znatne razlike financijskih i organizacijskih čimbenika prema pokazateljima poduzeća.

Nadalje, istraživanje vezano uz financijske i organizacijske čimbenike trebalo bi proširiti i na više kritičnih čimbenika uspješnosti (tablica 9.1) poput: spremnost organizacije na promjene, podrška i uključenost vrhovnog menadžmenta i dr. Na osnovu takvih dodatnih analiza proizašli bi modeli učinkovitoga upravljanja prema pokazateljima poduzeća koji uključuju veći broj čimbenika uspješnosti, a time se realnije opisuju potrebe poduzeća.

12. ZAKLJUČAK

U radu su opisane suvremene metode upravljanja proizvodnim sustavima (poduzećima). Glavno obilježje suvremenog okruženja je stalna promjena konkurentnosti pa poduzeća moraju posvetiti znatno vrijeme i resurse kako bi ostvarila svoje strateške ciljeve. Zbog želje za povećanjem učinkovitosti i produktivnosti poduzeća te razvoja novih tehnologija nužne su promjene poslovnih procesa. Pojavljuju se novi zahtjevi na upravljačke sustave poduzeća, koji povlače za sobom i razvoj novih metoda i alata učinkovitoga upravljanja poduzećima.

Istraživačkim radom, provedenim anketama i na osnovi detaljno obrađenih suvremenih metoda i modela vitke proizvodnje (e. *Lean Production*) i zelene proizvodnje (e. *Green Production*), primjenjujući saznanja o okruženju u Republici Hrvatskoj, izrađeni su modeli učinkovitoga upravljanja poduzećem prema pokazateljima poduzeća. U navedenim modelima, alatima vitke proizvodnje utječe se na smanjenje gubitaka u poslovanju poduzeća, dok se načelima zelene proizvodnje utječe na smanjenje prekomjerne primjene energije i štetnih emisija u okoliš te povećava primjena materijala koji se mogu reciklirati.

Istraživački rad proveden tijekom izrade ove disertacije rezultirao je sljedećim znanstvenim doprinosima u području upravljanja poduzećima:

- Definirani su ključni čimbenici za uspješnu implementaciju vitkih alata (potencijal vitkog alata za smanjenje gubitaka u poslovanju poduzeća, financijski i organizacijski čimbenici implementacije vitkih alata).
- Izrađen je opći model učinkovitoga upravljanja poduzećem s ključnim čimbenicima koji vodstvu poduzeća daju smjernice za uspješnu implementaciju vitkih i zelenih alata u hrvatska poduzeća.
- Izrađeni su modeli učinkovitoga upravljanja prema pokazateljima poduzeća (proizvodna mikropoduzeća, proizvodna mala, srednje velika i velika poduzeća, uslužna mikropoduzeća, uslužna mala, srednje velika i velika poduzeća) na osnovi općeg modela učinkovitoga upravljanja poduzećem te je postavljena vitka i zelena metrika.

Izrađeni model učinkovitoga upravljanja proizvodnim malim, srednje velikim i velikim poduzećem verificiran je u velikom proizvodnom poduzeću Elektro-Kontakt d.d.. Primjenom

najutjecajnijih vitkih alata koji su dobiveni izrađenim modelom učinkovitoga upravljanja u poduzeću Elektro-Kontakt d.d. ostvareni su vrlo dobri poslovni rezultati. Na primjeru iskorištavanja otpadne topline s kompresora pokazano je da je primjenom vitkog alata Kaizen, uz znatnu financijsku uštedu, ostvareno i znatno smanjenje emisije štetnih plinova.

Iz navedenog se može reći da se razvijeni modeli učinkovitoga upravljanja poduzećima mogu uspješno primijeniti u hrvatskim poduzećima. Time se postiže njihova veća fleksibilnost i učinkovitost, a samim time i konkurentnost i briga za očuvanje okoliša, uz istodobnu veću motivaciju i zadovoljstvo zaposlenika.

Nastavak ovog istraživanja trebalo bi usmjeriti prema dodatnim poboljšanjima i unaprjeđenjima pojedinih dijelova modela. U budućim istraživanjima bilo bi potrebno provesti slične analize na više kritičnih čimbenika uspješnosti prema pokazateljima poduzeća. Time bi se obuhvatilo više čimbenika koji realnije opisuju potrebe poduzeća.

13. LITERATURA

1. Anil Kumar, S., Suresh, N.: *Operations Management*, New Age International Ltd, New Delhi, 2009.
2. Bellgran, M., Säfssten, K.: *Production Development: Design and Operation of Production Systems*, Springer London Dordrecht Heidelberg, New York, 2010.
3. Grupa autora: *Inženjerski priručnik; 4/III, Organizacija proizvodnje*, Školska knjiga, d.d., Zagreb, 2002.
4. Previšić, J., Ozretić, D.Đ.: *Međunarodni marketing*, Masmedia, Zagreb, 1999.
5. Štefanić, N., Križan, O., Čala, I.: *Models and Methods of Production Management*, *Strojarstvo* 50, pp. 175-184, 2008.
6. Katsanos, E., Bitos, A.: *Methods of Industrial Production Management: A Critical Review*, Proceedings of the 1st International Conference on Manufacturing Engineering, Quality and Production Systems (MEWAPS '09), Transilvania University of Brasov, Romania, 2009.
7. Prajogo, D.I., Sohal, A.S.: *The integration of TQM and technology/R&D management in determining quality and innovation performance*, *The International Journal of Management Science*, Omega 34, pp. 296-312, 2006.
8. Veža, I.: *Formiranje Lean sistema kroz definiranje poslovnih strategija (Hoshin Kanri) i implementiranje kontinuiranog unaprjeđenja na svim razinama tvrtke (Kaizen)*, Green and Lean Production GALP 2011, 1. Konferencija o zelenoj i vitkoj proizvodnji i uslugama, Lean menadžment inicijativa, Zagreb, studeni 2011.
9. Grupa autora: *Opća enciklopedija: Industrija, Industrijska revolucija*, Jugoslavenski leksikografski zavod, Treće izdanje, treći svezak, Zagreb, 1979.
10. Kennedy, A.G.: *An Assessment of the Use of Research Methods in Lean Manufacturing Environments: An Introduction of the Relational Theory of Continuous Improvement and the Seven Waste of Lean Research*, A dissertation submitted to the faculty of the school of education of the University of St. Thomas, Minnesota, 2011.
11. Thorsten, A.: *Lean production: Successful implementation of organisational change in operations instead of short term cost reduction efforts*, Lean Alliance GmbH, Seefeld, Germany, 2006.

12. Houshmand, M., Jamshidnezhad, B.: *An extended model of design process of lean production systems by means of process variables*, Robotics and Computer-Integrated Manufacturing 22, pp. 1-16, Elsevier Ltd., 2006.
13. Vranješ, B., Jerebić, B., Kunica, Z.: *Inženjerski priručnik: Proizvodno strojarstvo – Projektiranje proizvodnih sustava*, Školska knjiga, Zagreb, 2012.
14. Groover, Mikell, P.: *Fundamentals of modern manufacturing: materials, processes and systems*, 3rd ed., John Wiley & Sons, Inc., New Jersey, 2007.
15. Cajner, H.: *Višekriterijsko adaptivno oblikovanje planova pokusa*, Doktorski rad, FSB, Zagreb, 2011.
16. Kovačec, M.: *Upravljanje proizvodnjom i projektima*, Seminarski rad, FSB, Zagreb, 2009.
17. Jingshan, L., Semyon, M.M.: *Production systems engineering*, Springer Science+Business Media, New York, USA, 2009.
18. Sikavica, P., Bahtijarević-Šiber, F., Pološki Vokić, N.: *Temelji menadžmenta*, Školska knjiga, str. 37-45, Zagreb, 2008.
19. Čala, I.: *Proizvodni management*, Skripta s predavanja, FSB, Zagreb, 2003.
20. Borris, S.: *Total Productive Maintenance*, The McGraw-Hill Companies, USA, 2006.
21. Kobayashi, I.: *20 Keys to Workplace Improvement*, revised edition, Productivity Press, Cambridge, MA, 1998.
22. Efficiency Valuation Organization: *Međunarodni protokol za mjerenje i verifikaciju učinka*, Svezak 1, 2010.
23. Bosilj Vukšić, V., Ivančanin, T.: *Primjena koncepta six sigma u kreiranju usluga mobilnih mreža treće generacije*, Tehnički vjesnik 13, 2006.
24. Sánchez, J.M.: *Assessing Sustainability of the Continuous Improvement Throught the Identification of Enabling and Inhibiting Factors*, Dissertation, Virginia Polytechnic Institute and State University, Blacksburg, Virginia, 2012.
25. Baković, T.: *Šest sigma sustav za upravljanje kvalitetom*, Skripta s predavanja, Ekonomski fakultet Zagreb, Zagreb, 2014.
26. Pojasek, R.B.: *Lean, Six Sigma, and the System Approach: Management Initiatives for Process Improvement*, Environmental Quality Management, Wiley Periodicals Inc., Boston, USA, 2003.
27. Pestorius, M.S.: *Apply Six Sigma To Sales and Marketing*, Quality Progress, 2007.
28. Gunasekaran, A., Kobu, B.: *Modelling and analysis of business process reengineering*, International Journal of Production Research, Taylor & Francis Ltd, 2002.

29. Zygiaris, S.: *Business process re-engineering*, Innoregio, BPR HELAS SA, 2000.
30. Sepälä, J.: *The effect of balanced scorecard on strategy participation*, Master's Thesis, Aalto University School of Economics, Finland, 2010.
31. Kaplan, S., Norton, D.: *The Balanced Scorecard – Measures that Drive Performance*, Harvard Business Review, Boston, 1992.
32. Klaić, A.: *Pregled stanja i trendova u suvremenoj politici informacijske sigurnosti i metodologijama upravljanja informacijskom sigurnošću*, Ured Vijeća za nacionalnu sigurnost, 2010.
33. Kaplan, S., Norton, D.: *Balanced Scorecard – Translating Strategy into Action*, Harvard Business School Press, Boston, 1996.
34. Niven, P.: *Balanced scorecard for small & medium sized organizations*, Corporate Business in Control, 2011.
35. Veža, I., Kordić, Z.: *Prilog uvođenju koncepta "Cjelovitog produktivnog održavanja"*, Zbornik radova 7. međunarodnog savjetovanja Održavanje 2001, Opatija, 2001.
36. <http://www.leanproduction.com/tpm.html>, 08.03.2015.
37. Marchwinski J., Shoko, J., Schroeder, A.: *Lean Lexicon – a graphical glossary for Lean Thinkers*, The Lean Enterprise Institute, Cambridge, MA, USA, March 2008.
38. Dale, B.G., Wiele, T., Iwaarden, J.: *Managing Quality*, Wiley-Blackwell, 2013.
39. Hashmi, K.: *Introduction and Implementation of Total Quality Management (TQM)*, Pakistan Air Force Academy, 2004.
40. Petrarolo, D.: *Benchmarking Organisational Capability using The 20 Keys*, The South African Journal of Industrial Engineering, Johannesburg, 1997.
41. <http://www.odi.co.za/>, 11.03.2015.
42. Erceg, A.: <http://kvaliteta.inet.hr/e-quality/prethodni/13/prenosimo1.htm>, 10.03.2015.
43. Štefanić, N.: *Zelena i Vitka proizvodnja i usluge – prilike za hrvatska poduzeća*, Green and Lean Production GALP 2011, 1. Konferencija o zelenoj i vitkoj proizvodnji i uslugama, Lean menadžment inicijativa, Zagreb, studeni 2011.
44. Vrdoljak-Raguž, I.: <http://www.suvremena.hr/23409.aspx>, 18.3.2015.
45. Hegedić, M.: *Upravljanje znanjem i promjenama*, Vježbe, Poslovni sustavi, osnove menadžmenta, FSB, Zagreb, 2012.
46. Čiarniene, R., Vienažindienė, M.: *Lean Manufacturing: Theory and Practice*, Kaunas University of Technology, Economics and management, 2012.
47. Gonce, A., Somers, K.: *Lean for green manufacturing*, Climate Change Special Initiative, Energy Efficiency, 2010.

48. Bergmiller, G.G.: *Lean manufacturers transcendence to green manufacturing: Correlating the diffusion of lean and green manufacturing systems*, Doctor dissertation, University of South Florida, Scholar Commons, 2006.
49. Al-Fandi, L.: *A novel approach using lean and simulation modeling for effective green transformation for high-end server manufacturing*, Dissertation, Graduate School of Binghamton University, New York, 2011.
50. Shah, R., Ward, P.T.: *Defining and developing measures of lean production*, Journal of Operations Management 25, pp. 785-805, Elsevier, 2007.
51. Abdulmalek, F.A., Rajgopal, J.: *Analyzing the benefits of lean manufacturing and value stream mapping via simulation: A process sector case study*, International Journal of Production Economics 107, pp. 223-236, Elsevier, 2007.
52. Hicks, B.J.: *Lean information management: Understanding and eliminating waste*, International Journal of Information Management 27, pp. 233-249, Elsevier, 2007.
53. Mo, J.P.T.: *The role of lean in the application of information technology to manufacturing*, Computers in Industry 60, pp. 266-276, Elsevier, 2009.
54. Rubio, S., Corominas, A.: *Optimal manufacturing – remanufacturing policies in a lean production environment*, Computers & Industrial Engineering 55, pp. 234-242, Elsevier, 2008.
55. Demeter, K., Matyusz, Z.: *The impact of lean practices on inventory turnover*, International Journal of Production Economics, Elsevier, 2010.
56. Cuatrecasas, A.L.: *Design of a rapid response and high efficiency service by lean production principles: Methodology and evaluation of variability of performance*, International Journal of Production Economics 80, pp. 169-183, Elsevier, 2002.
57. Balle, M.: *Full Enterprise Lean*, Green and Lean Production GALP 2011, 1. Konferencija o zelenoj i vitkoj proizvodnji i uslugama, Lean menadžment inicijativa, Zagreb, studeni 2011.
58. Hart, S.: *How green production might sustain the world*, Journal of the Northwest Environment, pp. 4-14, 1994.
59. Ab. Rahman, M.N., Hernadewita, Md Deros, B., Yasin, R., M., Sopian, K., Zaharim, A.: *Applying Cleaner Production Concepts in Improving Quality of Environment*, Proceedings of the 2nd International Conference on Renewable Energy Sources (RES'08), Corfu, Greece, 2008.

60. Ioana, I.: *Clean technology form waste management*, Advances in Waste Management, 4th WSEAS International Conferences on Waste Management, Water Pollution, Air Pollution, Indoor climate, pp. 155-171, 2010.
61. Rujnić-Sokele. M., Šercer, M., Pilipović, A.: *Waste Packaging Mangement in Republic of Croatia*, 14th International Research/Expert Conference "Trends in the Developmnet of Machinery and Associated Technology", TMT 2010, Mediterranean Cruise, 11-18 September 2010.
62. Kovačec, M., Tošanović, N., Štefanić, N.: *Recycling of glass packaging in Republic of Croatia*, Recent researches in chemistry, biology, environment & culture, Montreux: WSEAS, 2011.
63. Vellini, M., Savioli, M.: *Energy and environmental analysis of glass container production and recycling*, Energy 34, pp. 2137-2143, Elsevier, 2009.
64. Ruth, M., Dell'Anno, P.: *An industrial ecology of the US glass industry*, Resources Policy, Vol. 23, No. 3, pp. 109-1024, Elsevier Science Ltd 1997.
65. Kovačec, M., Pilipović, A., Štefanić, N.: *Impact of glass cullet on the consumption of energy and environment in the production of glass packaging material*, Recent researches in chemistry, biology, environment & culture, Montreux: WSEAS, 2011.
66. Kelemeš, J.J., Varbanov, P.S., Pierucci, S., Huisingh, D.: *Minimising emissions and energy wastage by improved industrial processes and integration of renewable energy*, Journal of Cleaner Production 18, pp. 843-847, Elsevier, 2010.
67. Demirbas, A.: *Wastage management, waste resource facilities and waste conversion processes*, Energy Conversion and Management 52, pp. 1280-1287, Elsevier, 2011.
68. Christodoulou, A.: *Factors of success for the effective implementation of lean manufacturing projects within the banking sector in South Africa*, Gordon Institute of Business Science, University of Pretoria, 2008.
69. Deluka-Tibijaš, A., Karleuša, B., Dragičević, N.: *Pregled primjene metoda višekriterijske analize pri donošenju odluka o prometnoj infrastrukturi*, Građevinar 65, 7/2013.
70. Đukić, G., Stanić, A., Olujić, Č.: *AHP method as an aid in warehouse design process*, Proceedings of 9 th international scientific conference on production engineering CIM 2003.
71. Seyedi, S.N., Hakimi, S., Ahmadi, H.B., Rezvan, P., Izadifar, M.: *A Decision-Making Process for Selecting of Lean Tools Implementation Methods by Means of Analitical Hierarchy Process in Health Center*, Jurnal Teknologi, Penerbit UTM Press, 2013.

72. Ravikumar, M.M., Marimuthu, K., Parthiban, P., Abdul Zubar, H.: *Leanness Evaluation in 6 Manufacturing MSME's using AHP & SEM Techniques*, International Journal of Mechanical & Mechatronics Engineering, 2013.
73. <http://www.dzs.hr/Hrv/publication/subjects.htm>, 04.12.2014.
74. Verheugen, G.: *Nova definicija MSP-a, Vodič za korisnike*, Enterprise and industry publications, Europska komisija
75. *Zakon o poticanju razvoja malog gospodarstva*, Narodne novine br. 29/02, Zagreb, 2002.
76. Kujundžić-Tiljak, M., Ivanković, D.: *Testiranje hipoteza*, Medicinski fakultet Sveučilišta u Zagrebu, <http://www.mef.unizg.hr/meddb/slike/pisac15/file1525p15.pdf>, 28.3.2015.
77. Dujmić, D.: *Primjena višekriterijalnog odlučivanja u odabiru lokacije skladišta*, Diplomski rad, FSB, Zagreb, 2014.
78. Karleuša, B., Ožanić, N.: *Određivanje prioriteta u realizaciji vodnogospodarskih planova*, Građevinar 63, 2011.
79. Saaty, T.L.: *Decision making with the analytic hierarchy process*, Int. J. Services Sciences, 2008.
80. Lisjak, D.: *Primjena AHP metode kao alata za optimalni izbor opreme*, Održavanje u sustavu gospodarenja fizičkom imovinom, Hrvatsko društvo održavatelja, Zagreb, 2011.
81. Saaty, T.L.: *Feasibility Study of Prioritisation Method in AHP (Analytic Hierarchy Process)*, 1971.
82. Klanac, J., Perković, J., Krajnović, A.: *Primjena AHP i PROMETHEE metode na problem diverzifikacije*, Oeconomica Jadertina, 2013.
83. Konstantinos, P.: *The Analytic Hierarchy Process*, International Hellenic University
84. <http://www.elektrokontakt.hr>, 1.5.2015.
85. Stašić, T., Hucika, H.: *Preliminarni izračun primjene mjera energetske učinkovitosti povrata toplinske energije sa kompresora K3 i K4 u objektu F i kompresora K5 i K6 u objektu D tvrtke Elektro-Kontakt d.d. Zagreb*, HEP ESCO d.o.o., Zagreb, 2014.
86. Kovačec, M., Vnućec, V., Ribić, G.: *Izvješće o provedenom energetskom pregledu toplinske podstanice i kompresorske stanice – zgrade interne oznake "F"*, HEP ESCO d.o.o., Zagreb, 2014.
87. Fond za zaštitu okoliša i energetska učinkovitost: *Odluka o odabiru korisnika i dodjeli sredstava Fonda za zaštitu okoliša i energetska učinkovitost radi sufinanciranja projekta energetske učinkovitosti u industriji*, KLASA: 310-34/14-03/123, URBROJ: 563-02-2/91-15-4, Zagreb, 2015.
88. Tomić: *Termotehnički sustav Elektro-Kontakt d.d. – izvedeno stanje*, Zagreb, 2015.

14. PRILOZI

Anketa: Upravljanje poduzećima u RH

Anketa: Implementacija vitkih alata

Tablica 14.1. Matrica usporedbe alternativa prema potkriteriju 1. a)

Tablica 14.2. Matrica usporedbe alternativa prema potkriteriju 1. b)

Tablica 14.3. Matrica usporedbe alternativa prema potkriteriju 1. c)

Tablica 14.4. Matrica usporedbe alternativa prema potkriteriju 1. d)

Tablica 14.5. Matrica usporedbe alternativa prema potkriteriju 2. a)

Tablica 14.6. Matrica usporedbe alternativa prema potkriteriju 2. b)

Tablica 14.7. Matrica usporedbe alternativa prema potkriteriju 3. a)

Tablica 14.8. Matrica usporedbe alternativa prema potkriteriju 3. b)

Tablica 14.9. Matrica usporedbe alternativa prema potkriteriju 3. c)

Tablica 14.10. Matrica usporedbe alternativa prema potkriteriju 4. a)

Tablica 14.11. Matrica usporedbe alternativa prema potkriteriju 4. b)

Tablica 14.12. Matrica usporedbe alternativa prema potkriteriju 4. c)

Tablica 14.13. Matrica usporedbe alternativa prema potkriteriju 4. d)

Tablica 14.14. Matrica usporedbe alternativa prema potkriteriju 5. a)

Tablica 14.15. Matrica usporedbe alternativa prema potkriteriju 5. b)

Tablica 14.16. Matrica usporedbe alternativa prema potkriteriju 5. c)

Tablica 14.17. Matrica usporedbe alternativa prema kriteriju 6. a)

Tablica 14.18. Matrica usporedbe alternativa prema potkriteriju 7. a)

Tablica 14.19. Matrica usporedbe alternativa prema potkriteriju 7. b)

Tablica 14.20. Matrica usporedbe alternativa prema potkriteriju 7. c)

Tablica 14.21. Matrica usporedbe alternativa prema potkriteriju 7. d)

Tablica 14.22. Matrica usporedbe alternativa prema potkriteriju 8. a)

Tablica 14.23. Matrica usporedbe alternativa prema potkriteriju 8. b)

UPRAVLJANJE PODUZEĆIMA U RH

UVODNO O ANKETI

Cilj ankete prikupljanje je podataka o upravljanju poduzećima u RH, a oni će se upotrijebiti za potrebe izrade doktorskog rada. Anketa je anonimna te se **ni prema kojem kriteriju** neće pojedinačno izdvajati **ništa od navedenog**. Zato Vas molimo za iskrenost. Svi podaci obrađivat će se isključivo skupno, bez izdvajanja pojedinačnih informacija.

Molimo Vas da anketu popunite u potpunosti kako bismo dobili što više kvalitetnih podataka. Ako anketu ispunjavate u elektronskom obliku, na pitanja koja iziskuju zaokruživanje odgovora željene odgovore možete označiti drugom bojom (ili ih samo boldajte). Sve ostale odgovore jednostavno upišite na mjesto predviđeno za to.

PODACI O PODUZEĆU I INTERVJUIRANOJ OSOBI

1. Djelatnost tvrtke: _____
2. Broj zaposlenika tvrtke: _____
3. Radno mjesto intervjuirane osobe: _____
4. Odjel, sektor: _____

1. Kada govorite o učinkovitom upravljanju poduzećem, mislite li na: (moguće zaokružiti do 5 izjava koje smatrate najvažnijima)

- a. metodu za smanjenje broja zaposlenih
- b. skup tehnika za unaprjeđenje proizvodnje/usluge i operacija
- c. timski rad i kontinuirano unaprjeđenje
- d. stalno smanjenje nepotrebnih zadataka
- e. potpuno integriranu psihologiju menadžmenta
- f. način kreiranja novog načina rada i poslovanja
- g. sustav za organiziranje i upravljanje razvojem proizvoda/usluga, operacija, nabave i odnosa s kupcima
- h. sustav reorganizacije poduzeća prema vrstama proizvoda/usluga i prema vrijednosti
- i. sustav za proizvodnju proizvoda s malo grešaka
- j. psihologija koja je potpuno usmjerena na kupce/klijente

2. Procijenite koja od sljedećih tvrdnji, prema Vašem mišljenju, najviše utječe na uspješnost nekog poduzeća. Rangirajte navedene tvrdnje prema važnosti utjecaja ocjenama od 1 do 6 (pri čemu 1 znači vrlo visok utjecaj, a 6 najmanji utjecaj)

- | | |
|--------------------------------------------------------|-------|
| a. uključenost i podrška menadžmenta | _____ |
| b. vještine i stručnost zaposlenika | _____ |
| c. raspoloživost financijskih sredstava | _____ |
| d. razrađena poslovna strategija | _____ |
| e. kontinuirano ulaganje u razvoj poduzeća | _____ |
| f. dobra komunikacija na svim razinama unutar poduzeća | _____ |

3. Vaše poduzeće investiralo bi u povećanje učinkovitosti poslovanja zbog/radi? (označite do 3 odgovora)

- a. stalnog pritiska za unapređenjem operacija
- b. postizanja kompetitivne prednosti u cijeni i usluzi
- c. povećanja profita
- d. kraćeg roka isporuke kupcima
- e. smanjenja cijene kupcima

4. Ovisi li djelatnost Vašeg poduzeća uglavnom o Vašim dobavljačima (kooperantima), npr. isporuci: sirovina, materijala, proizvoda, usluga i sl. Da / Ne

Ako je odgovor na prethodno pitanje bio "da", navedite na koji način/kojim sredstvima komuniciranja uspostavljate kontakt s dobavljačima (kooperantima)?

- | | |
|--------------------------------------------------|---------|
| - tel/fax-om: | Da / Ne |
| - internetom | Da / Ne |
| - posebnim programskim alatima (mrežni programi) | Da / Ne |
| - ostalo (navedite) _____ | |

5. Procijenite na skali od 1 do 5 sljedeće tvrdnje koje se odnose na komunikaciju pri provedbi projekta.

1 = vrlo mala aktivnost; 2 = mala aktivnost; 3 = prosjek; 4 = visok stupanj aktivnosti;

5 = vrlo visok stupanj aktivnosti

- | | | | | | |
|--------------------------------------------------------------------------------|---|---|---|---|---|
| a. projekt ima komunikacijski plan | 1 | 2 | 3 | 4 | 5 |
| b. projekt ima definiranu komunikaciju s poslovnim jedinicama | 1 | 2 | 3 | 4 | 5 |
| c. većina zaposlenih razumije projekt i koji se cilj želi postići | 1 | 2 | 3 | 4 | 5 |
| d. svi dioničari efikasno i kontinuirano komuniciraju o svrsi projekta i cilju | 1 | 2 | 3 | 4 | 5 |

6. Odaberite alat koji se primjenjuje u Vašem poduzeću da biste postali učinkovitije poduzeće (upišite znak „X“ ispod kategorije koja Vam najviše odgovara)

Rb.	KATEGORIJE ALATI	ne primjenjuje se	primjenjuje se samo lokalno	primjenjuje se u cijeloj organizaciji	primjenjuje se u cijelom tijeku vrijednosti uključujući i kupce i dobavljače
1.	Mapiranje procesa (međusobno dovođenje u vezu svih aktivnosti, procesa, tokova - materijala, informacija, i sl.)				
2.	5S (red, urednost, nezagađenost, čistoća, disciplina) - čisto i sigurno radno okruženje				
3.	Tijek proizvodnje/usluge				
4.	Vrijeme obrade i standardizacija				
5.	SMED (brza promjena alata, smanjenje vremena proizvodnje/usluge)				
6.	KANBAN (sustav smanjenja zaliha u proizvodnji/usluzi), standardni materijali				
7.	Šest Sigma (upravljanje kvalitetom proizvoda/usluge) – skup metodoloških principa i statističkih alata za kontinuirano poboljšanje procesa				
8.	TPM – cjelokupno produktivno održavanje				
9.	ISO – Međunarodna organizacija za standarde				
10.	Ostalo (navedite)				

7. Prema LEAN⁴ metodologiji postoji 7+1 vrsta gubitaka u poslovanju poduzeća. Na svakom pitanju (1 – 8) odaberite jedan ili više ponuđenih gubitaka (a, b, c ili d) koji se pojavljuju u Vašem poduzeću i odgovorite koliki je potencijal za smanjenje tog gubitka u Vašem poduzeću.

0 = nema potencijala; 1 = mali potencijal; 2 = srednji potencijal; 3 = veliki potencijal

Rb.	Opis gubitka	Potencijal
1.	a) Stvaranje proizvoda/usluga koji se ne mogu plasirati na tržištu	0 1 2 3
	b) Stvaranje dokumentacije koju nitko ne zahtjeva	0 1 2 3
	c) Slanje uputa prema previše (premalo) ljudi	0 1 2 3
	d) Proizvodnja za "svaki slučaj"	0 1 2 3
2.	a) Visoke zalihe ("zamrznuti kapital" u skladištima)	0 1 2 3
	b) Više materijala i informacija nego što je potrebno	0 1 2 3
3.	a) Nepotrebno kretanje materijala (obradaka) između operacija	0 1 2 3
	b) Neučinkovito i nepotrebno kretanje informacija	0 1 2 3
	c) Neuspješna komunikacija: gubitak podataka, nekompatibilnost, nepouzdanost informacija	0 1 2 3
4.	a) Vrijeme čekanja materijala između operacija	0 1 2 3
	b) Čekanje radnika na strojevima	0 1 2 3
	c) Čekanje na podatke, informacije, odluke, potpis, odobrenje ...	0 1 2 3
	d) Čekanje na isporuku (npr. kasni sirovina)	0 1 2 3
5.	a) Loš raspored strojeva – nepotrebno kretanje radnika	0 1 2 3
	b) Ljudi se trebaju kretati kako bi došli do informacija	0 1 2 3
	c) Ručni rad kako bi se kompenzirali nedostaci u procesu	0 1 2 3
6.	a) Prekid toka zbog grešaka, nepotrebna vremena, troškovi i prostor za analizu i otklanjanje nepotpune, netočne, nepravodobne informacije	0 1 2 3
7.	a) Predimenzionirani strojevi	0 1 2 3
	b) Kriva ili nedostajuća tehnološka oprema	0 1 2 3
	c) Previše procesa obrade	0 1 2 3
	d) Loš dizajn proizvoda, koji zahtijeva previše koraka obrade	0 1 2 3
8.	a) Radnike se ne uključuje u aktivnosti poboljšanja procesa	0 1 2 3
	b) Ne uključivanje u Kaizen radionice (<i>razvoj kreativnosti zaposlenika i njihovo fokusiranje na određene radne zadatke s ciljem poboljšanja kvalitete rada i eliminacije rasipanja</i>)	0 1 2 3

⁴ LEAN – proizvodna filozofija koja, kada je implementirana, skraćuje vrijeme od kupčeve narudžbe do isporuke gotovog proizvoda, eliminirajući sve izvore rasipanja (gubitaka) u proizvodnom procesu

IMPLEMENTACIJA VITKIH ALATA

UVODNO O ANKETI

Financijski i organizacijski čimbenici jedni su od najvažnijih čimbenika kod odabira vitkih alata prilikom implementacije u poduzeće su.

Cilj ankete prikupljanje je podataka vezanih uz implementaciju vitkih alata u poduzeće, odnosno: troškove implementacije vitkih alata (cijena) te promjene u organizaciji poduzeća kod implementacije vitkih alata (organizacijske promjene, vrijeme implementacije, uključenost rukovodstva poduzeća, "težina implementacije" ...). Molim da za usporedbu vitkih alata u parovima primijenite Saatyjevu skalu.

Anketa je anonimna, pa se **ni po kojem kriteriju** neće pojedinačno izdvajati **ništa od navedenog**. Svi podaci obrađivat će se isključivo skupno, bez izdvajanja pojedinačnih informacija. Molimo Vas da anketu popunite u potpunosti kako bismo dobili što više kvalitetnih podataka. Ako anketu ispunjavate u elektronskom obliku, na pitanja koja iziskuju zaokruživanje odgovora željene odgovore možete označiti drugom bojom (ili ih samo boldajte). Sve ostale odgovore jednostavno upišite na mjesto predviđeno za to.

a) Cijena implementacije vitkih alata

5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Jidoka
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	JIT
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Kaizen
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Kanban
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Kont. tok
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Map. toka vr.
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	PokaYoke
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	SMED
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Standard. rad
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Taktno vr.
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	TPM

b) Promjene u organizaciji poduzeća kod implementacije vitkih alata

5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Jidoka
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	JIT
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Kaizen
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Kanban
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Kont. tok
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Map. toka vr.
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	PokaYoke
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	SMED
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Standard. rad
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Taktno vr.
5S	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	TPM

Tablica 14.1. Matrica usporedbe alternativa prema potkriteriju 1. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1/6	1	1/6	1	1	1	1	1	1	1
Jidoka	1	1	1/6	1	1/6	1	1	1	1	1	1	1
JIT	6	6	1	6	1	6	6	6	6	6	6	6
Kaizen	1	1	1/6	1	1/6	1	1	1	1	1	1	1
Kanban	6	6	1	6	1	6	6	6	6	6	6	6
Kont. tok	1	1	1/6	1	1/6	1	1	1	1	1	1	1
Map. toka vr.	1	1	1/6	1	1/6	1	1	1	1	1	1	1
Poka Yoke	1	1	1/6	1	1/6	1	1	1	1	1	1	1
SMED	1	1	1/6	1	1/6	1	1	1	1	1	1	1
Standard. rad	1	1	1/6	1	1/6	1	1	1	1	1	1	1
Taktno vr.	1	1	1/6	1	1/6	1	1	1	1	1	1	1
TPM	1	1	1/6	1	1/6	1	1	1	1	1	1	1

Tablica 14.2. Matrica usporedbe alternativa prema potkriteriju 1. b)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1/5	1	1	1	1	1	1/7	1	1
Jidoka	1	1	1	1/5	1	1	1	1	1	1/7	1	1
JIT	1	1	1	1/5	1	1	1	1	1	1/7	1	1
Kaizen	5	5	5	1	5	5	5	5	5	1/2	5	5
Kanban	1	1	1	1/5	1	1	1	1	1	1/7	1	1
Kont. tok	1	1	1	1/5	1	1	1	1	1	1/7	1	1
Map. toka vr.	1	1	1	1/5	1	1	1	1	1	1/7	1	1
Poka Yoke	1	1	1	1/5	1	1	1	1	1	1/7	1	1
SMED	1	1	1	1/5	1	1	1	1	1	1/7	1	1
Standard. rad	7	7	7	2	7	7	7	7	7	1	7	7
Taktno vr.	1	1	1	1/5	1	1	1	1	1	1/7	1	1
TPM	1	1	1	1/5	1	1	1	1	1	1/7	1	1

Tablica 14.3. Matrica usporedbe alternativa prema potkriteriju 1. c)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1/6	1	1	1	1/6	1	1
Jidoka	1	1	1	1	1	1/6	1	1	1	1/6	1	1
JIT	1	1	1	1	1	1/6	1	1	1	1/6	1	1
Kaizen	1	1	1	1	1	1/6	1	1	1	1/6	1	1
Kanban	1	1	1	1	1	1/6	1	1	1	1/6	1	1
Kont. tok	6	6	6	6	6	1	6	6	6	1	6	6
Map. toka vr.	1	1	1	1	1	1/6	1	1	1	1/6	1	1
Poka Yoke	1	1	1	1	1	1/6	1	1	1	1/6	1	1
SMED	1	1	1	1	1	1/6	1	1	1	1/6	1	1
Standard. rad	6	6	6	6	6	1	6	6	6	1	6	6
Taktno vr.	1	1	1	1	1	1/6	1	1	1	1/6	1	1
TPM	1	1	1	1	1	1/6	1	1	1	1/6	1	1

Tablica 14.4. Matrica usporedbe alternativa prema potkriteriju 1. d)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Jidoka	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
JIT	5	5	1	5	1/3	5	5	5	1/2	5	1/2	5
Kaizen	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Kanban	8	8	3	8	1	8	8	8	2	8	3	8
Kont. tok	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Map. toka vr.	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Poka Yoke	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
SMED	7	7	2	7	1/2	7	7	7	1	7	2	7
Standard. rad	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1
Taktno vr.	6	6	2	6	1/3	6	6	6	1/2	6	1	6
TPM	1	1	1/5	1	1/8	1	1	1	1/7	1	1/6	1

Tablica 14.5. Matrica usporedbe alternativa prema potkriteriju 2. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1/9	1	1	1	1	1	1	1	1	1
Jidoka	1	1	1/9	1	1	1	1	1	1	1	1	1
JIT	9	9	1	9	9	9	9	9	9	9	9	9
Kaizen	1	1	1/9	1	1	1	1	1	1	1	1	1
Kanban	1	1	1/9	1	1	1	1	1	1	1	1	1
Kont. tok	1	1	1/9	1	1	1	1	1	1	1	1	1
Map. toka vr.	1	1	1/9	1	1	1	1	1	1	1	1	1
Poka Yoke	1	1	1/9	1	1	1	1	1	1	1	1	1
SMED	1	1	1/9	1	1	1	1	1	1	1	1	1
Standard. rad	1	1	1/9	1	1	1	1	1	1	1	1	1
Taktno vr.	1	1	1/9	1	1	1	1	1	1	1	1	1
TPM	1	1	1/9	1	1	1	1	1	1	1	1	1

Tablica 14.6. Matrica usporedbe alternativa prema potkriteriju 2. b)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
Jidoka	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
JIT	8	8	1	8	2	3	8	8	8	8	8	8
Kaizen	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
Kanban	7	7	1/2	7	1	2	7	7	7	7	7	7
Kont. tok	6	6	1/3	6	1/2	1	6	6	6	6	6	6
Map. toka vr.	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
Poka Yoke	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
SMED	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
Standard. rad	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
Taktno vr.	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1
TPM	1	1	1/8	1	1/7	1/6	1	1	1	1	1	1

Tablica 14.7. Matrica usporedbe alternativa prema potkriteriju 3. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1	1/9	1	1	1	1	1
Jidoka	1	1	1	1	1	1	1/9	1	1	1	1	1
JIT	1	1	1	1	1	1	1/9	1	1	1	1	1
Kaizen	1	1	1	1	1	1	1/9	1	1	1	1	1
Kanban	1	1	1	1	1	1	1/9	1	1	1	1	1
Kont. tok	1	1	1	1	1	1	1/9	1	1	1	1	1
Map. toka vr.	9	9	9	9	9	9	1	9	9	9	9	9
Poka Yoke	1	1	1	1	1	1	1/9	1	1	1	1	1
SMED	1	1	1	1	1	1	1/9	1	1	1	1	1
Standard. rad	1	1	1	1	1	1	1/9	1	1	1	1	1
Taktno vr.	1	1	1	1	1	1	1/9	1	1	1	1	1
TPM	1	1	1	1	1	1	1/9	1	1	1	1	1

Tablica 14.8. Matrica usporedbe alternativa prema potkriteriju 3. b)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1/7	1/7	1	1	1	1	1
Jidoka	1	1	1	1	1	1/7	1/7	1	1	1	1	1
JIT	1	1	1	1	1	1/7	1/7	1	1	1	1	1
Kaizen	1	1	1	1	1	1/7	1/7	1	1	1	1	1
Kanban	1	1	1	1	1	1/7	1/7	1	1	1	1	1
Kont. tok	7	7	7	7	7	1	1	7	7	7	7	7
Map. toka vr.	7	7	7	7	7	1	1	7	7	7	7	7
Poka Yoke	1	1	1	1	1	1/7	1/7	1	1	1	1	1
SMED	1	1	1	1	1	1/7	1/7	1	1	1	1	1
Standard. rad	1	1	1	1	1	1/7	1/7	1	1	1	1	1
Taktno vr.	1	1	1	1	1	1/7	1/7	1	1	1	1	1
TPM	1	1	1	1	1	1/7	1/7	1	1	1	1	1

Tablica 14.9. Matrica usporedbe alternativa prema potkriteriju 3. c)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1/6	1	1	1	1	1	1	1/5	1	1
Jidoka	1	1	1/6	1	1	1	1	1	1	1/5	1	1
JIT	6	6	1	6	6	6	6	6	6	2	6	6
Kaizen	1	1	1/6	1	1	1	1	1	1	1/5	1	1
Kanban	1	1	1/6	1	1	1	1	1	1	1/5	1	1
Kont. tok	1	1	1/6	1	1	1	1	1	1	1/5	1	1
Map. toka vr.	1	1	1/6	1	1	1	1	1	1	1/5	1	1
Poka Yoke	1	1	1/6	1	1	1	1	1	1	1/5	1	1
SMED	1	1	1/6	1	1	1	1	1	1	1/5	1	1
Standard. rad	5	5	1/2	5	5	5	5	5	5	1	5	5
Taktno vr.	1	1	1/6	1	1	1	1	1	1	1/5	1	1
TPM	1	1	1/6	1	1	1	1	1	1	1/5	1	1

Tablica 14.10. Matrica usporedbe alternativa prema potkriteriju 4. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1/9	1	1	1	1	1/3	1
Jidoka	1	1	1	1	1	1/9	1	1	1	1	1/3	1
JIT	1	1	1	1	1	1/9	1	1	1	1	1/3	1
Kaizen	1	1	1	1	1	1/9	1	1	1	1	1/3	1
Kanban	1	1	1	1	1	1/9	1	1	1	1	1/3	1
Kont. tok	9	9	9	9	9	1	9	9	9	9	3	9
Map. toka vr.	1	1	1	1	1	1/9	1	1	1	1	1/3	1
Poka Yoke	1	1	1	1	1	1/9	1	1	1	1	1/3	1
SMED	1	1	1	1	1	1/9	1	1	1	1	1/3	1
Standard. rad	1	1	1	1	1	1/9	1	1	1	1	1/3	1
Taktno vr.	3	3	3	3	3	1/3	3	3	3	3	1	3
TPM	1	1	1	1	1	1/9	1	1	1	1	1/3	1

Tablica 14.11. Matrica usporedbe alternativa prema potkriteriju 4. b)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1/7	1	1	1	1	1	1
Jidoka	1	1	1	1	1	1/7	1	1	1	1	1	1
JIT	1	1	1	1	1	1/7	1	1	1	1	1	1
Kaizen	1	1	1	1	1	1/7	1	1	1	1	1	1
Kanban	1	1	1	1	1	1/7	1	1	1	1	1	1
Kont. tok	7	7	7	7	7	1	7	7	7	7	7	7
Map. toka vr.	1	1	1	1	1	1/7	1	1	1	1	1	1
Poka Yoke	1	1	1	1	1	1/7	1	1	1	1	1	1
SMED	1	1	1	1	1	1/7	1	1	1	1	1	1
Standard. rad	1	1	1	1	1	1/7	1	1	1	1	1	1
Taktno vr.	1	1	1	1	1	1/7	1	1	1	1	1	1
TPM	1	1	1	1	1	1/7	1	1	1	1	1	1

Tablica 14.12. Matrica usporedbe alternativa prema potkriteriju 4. c)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	3	3	1/2	3	3	3	3	3	1/3	3	3
Jidoka	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
JIT	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
Kaizen	2	6	6	1	6	6	6	6	6	1/2	6	6
Kanban	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
Kont. tok	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
Map. toka vr.	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
Poka Yoke	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
SMED	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
Standard. rad	3	8	8	2	8	8	8	8	8	1	8	8
Taktno vr.	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1
TPM	1/3	1	1	1/6	1	1	1	1	1	1/8	1	1

Tablica 14.13. Matrica usporedbe alternativa prema potkriteriju 4. d)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1/7	1	1	1	1	1	1	1	1	1
Jidoka	1	1	1/7	1	1	1	1	1	1	1	1	1
JIT	7	7	1	7	7	7	7	7	7	7	7	7
Kaizen	1	1	1/7	1	1	1	1	1	1	1	1	1
Kanban	1	1	1/7	1	1	1	1	1	1	1	1	1
Kont. tok	1	1	1/7	1	1	1	1	1	1	1	1	1
Map. toka vr.	1	1	1/7	1	1	1	1	1	1	1	1	1
Poka Yoke	1	1	1/7	1	1	1	1	1	1	1	1	1
SMED	1	1	1/7	1	1	1	1	1	1	1	1	1
Standard. rad	1	1	1/7	1	1	1	1	1	1	1	1	1
Taktno vr.	1	1	1/7	1	1	1	1	1	1	1	1	1
TPM	1	1	1/7	1	1	1	1	1	1	1	1	1

Tablica 14.14. Matrica usporedbe alternativa prema potkriteriju 5. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1	1/9	1	1	1	1	1
Jidoka	1	1	1	1	1	1	1/9	1	1	1	1	1
JIT	1	1	1	1	1	1	1/9	1	1	1	1	1
Kaizen	1	1	1	1	1	1	1/9	1	1	1	1	1
Kanban	1	1	1	1	1	1	1/9	1	1	1	1	1
Kont. tok	1	1	1	1	1	1	1/9	1	1	1	1	1
Map. toka vr.	9	9	9	9	9	9	1	9	9	9	9	9
Poka Yoke	1	1	1	1	1	1	1/9	1	1	1	1	1
SMED	1	1	1	1	1	1	1/9	1	1	1	1	1
Standard. rad	1	1	1	1	1	1	1/9	1	1	1	1	1
Taktno vr.	1	1	1	1	1	1	1/9	1	1	1	1	1
TPM	1	1	1	1	1	1	1/9	1	1	1	1	1

Tablica 14.15. Matrica usporedbe alternativa prema potkriteriju 5. b)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	9	9	9	9	9	9	9	9	9	9	9
Jidoka	1/9	1	1	1	1	1	1	1	1	1	1	1
JIT	1/9	1	1	1	1	1	1	1	1	1	1	1
Kaizen	1/9	1	1	1	1	1	1	1	1	1	1	1
Kanban	1/9	1	1	1	1	1	1	1	1	1	1	1
Kont. tok	1/9	1	1	1	1	1	1	1	1	1	1	1
Map. toka vr.	1/9	1	1	1	1	1	1	1	1	1	1	1
Poka Yoke	1/9	1	1	1	1	1	1	1	1	1	1	1
SMED	1/9	1	1	1	1	1	1	1	1	1	1	1
Standard. rad	1/9	1	1	1	1	1	1	1	1	1	1	1
Taktno vr.	1/9	1	1	1	1	1	1	1	1	1	1	1
TPM	1/9	1	1	1	1	1	1	1	1	1	1	1

Tablica 14.16. Matrica usporedbe alternativa prema potkriteriju 5. c)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1	1	1	1	1	1	1/7
Jidoka	1	1	1	1	1	1	1	1	1	1	1	1/7
JIT	1	1	1	1	1	1	1	1	1	1	1	1/7
Kaizen	1	1	1	1	1	1	1	1	1	1	1	1/7
Kanban	1	1	1	1	1	1	1	1	1	1	1	1/7
Kont. tok	1	1	1	1	1	1	1	1	1	1	1	1/7
Map. toka vr.	1	1	1	1	1	1	1	1	1	1	1	1/7
Poka Yoke	1	1	1	1	1	1	1	1	1	1	1	1/7
SMED	1	1	1	1	1	1	1	1	1	1	1	1/7
Standard. rad	1	1	1	1	1	1	1	1	1	1	1	1/7
Taktno vr.	1	1	1	1	1	1	1	1	1	1	1	1/7
TPM	7	7	7	7	7	7	7	7	7	7	7	1

Tablica 14.17. Matrica usporedbe alternativa prema kriteriju 6. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1/3	4	4	4	4	4	1/2	4	1	4	1/2
Jidoka	3	1	9	9	9	9	9	2	9	3	9	2
JIT	1/4	1/9	1	1	1	1	1	1/8	1	1/4	1	1/8
Kaizen	1/4	1/9	1	1	1	1	1	1/8	1	1/4	1	1/8
Kanban	1/4	1/9	1	1	1	1	1	1/8	1	1/4	1	1/8
Kont. tok	1/4	1/9	1	1	1	1	1	1/8	1	1/4	1	1/8
Map. toka vr.	1/4	1/9	1	1	1	1	1	1/8	1	1/4	1	1/8
Poka Yoke	2	1/2	8	8	8	8	8	1	8	2	8	1
SMED	1/4	1/9	1	1	1	1	1	1/8	1	1/4	1	1/8
Standard. rad	1	1/3	4	4	4	4	4	1/2	4	1	4	1/2
Taktno vr.	1/4	1/9	1	1	1	1	1	1/8	1	1/4	1	1/8
TPM	2	1/2	8	8	8	8	8	1	8	2	8	1

Tablica 14.18. Matrica usporedbe alternativa prema potkriteriju 7. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1/2	1	1	1	1	1	1	1	1
Jidoka	1	1	1	1/2	1	1	1	1	1	1	1	1
JIT	1	1	1	1/2	1	1	1	1	1	1	1	1
Kaizen	2	2	2	1	2	2	2	2	2	2	2	2
Kanban	1	1	1	1/2	1	1	1	1	1	1	1	1
Kont. tok	1	1	1	1/2	1	1	1	1	1	1	1	1
Map. toka vr.	1	1	1	1/2	1	1	1	1	1	1	1	1
Poka Yoke	1	1	1	1/2	1	1	1	1	1	1	1	1
SMED	1	1	1	1/2	1	1	1	1	1	1	1	1
Standard. rad	1	1	1	1/2	1	1	1	1	1	1	1	1
Taktno vr.	1	1	1	1/2	1	1	1	1	1	1	1	1
TPM	1	1	1	1/2	1	1	1	1	1	1	1	1

Tablica 14.19. Matrica usporedbe alternativa prema potkriteriju 7. b)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1	1	1	1	1	1	1	1	1/8
Jidoka	1	1	1	1	1	1	1	1	1	1	1	1/8
JIT	1	1	1	1	1	1	1	1	1	1	1	1/8
Kaizen	1	1	1	1	1	1	1	1	1	1	1	1/8
Kanban	1	1	1	1	1	1	1	1	1	1	1	1/8
Kont. tok	1	1	1	1	1	1	1	1	1	1	1	1/8
Map. toka vr.	1	1	1	1	1	1	1	1	1	1	1	1/8
Poka Yoke	1	1	1	1	1	1	1	1	1	1	1	1/8
SMED	1	1	1	1	1	1	1	1	1	1	1	1/8
Standard. rad	1	1	1	1	1	1	1	1	1	1	1	1/8
Taktno vr.	1	1	1	1	1	1	1	1	1	1	1	1/8
TPM	8	8	8	8	8	8	8	8	8	8	8	1

Tablica 14.20. Matrica usporedbe alternativa prema potkriteriju 7. c)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1/4	1	1	1/9	1	1	1	1	1
Jidoka	1	1	1	1/4	1	1	1/9	1	1	1	1	1
JIT	1	1	1	1/4	1	1	1/9	1	1	1	1	1
Kaizen	4	4	4	1	4	4	1/2	4	4	4	4	4
Kanban	1	1	1	1/4	1	1	1/9	1	1	1	1	1
Kont. tok	1	1	1	1/4	1	1	1/9	1	1	1	1	1
Map. toka vr.	9	9	9	2	9	9	1	9	9	9	9	9
Poka Yoke	1	1	1	1/4	1	1	1/9	1	1	1	1	1
SMED	1	1	1	1/4	1	1	1/9	1	1	1	1	1
Standard. rad	1	1	1	1/4	1	1	1/9	1	1	1	1	1
Taktno vr.	1	1	1	1/4	1	1	1/9	1	1	1	1	1
TPM	1	1	1	1/4	1	1	1/9	1	1	1	1	1

Tablica 14.21. Matrica usporedbe alternativa prema potkriteriju 7. d)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1/7	1	1	1	1	1	1	1	1
Jidoka	1	1	1	1/7	1	1	1	1	1	1	1	1
JIT	1	1	1	1/7	1	1	1	1	1	1	1	1
Kaizen	7	7	7	1	7	7	7	7	7	7	7	7
Kanban	1	1	1	1/7	1	1	1	1	1	1	1	1
Kont. tok	1	1	1	1/7	1	1	1	1	1	1	1	1
Map. toka vr.	1	1	1	1/7	1	1	1	1	1	1	1	1
Poka Yoke	1	1	1	1/7	1	1	1	1	1	1	1	1
SMED	1	1	1	1/7	1	1	1	1	1	1	1	1
Standard. rad	1	1	1	1/7	1	1	1	1	1	1	1	1
Taktno vr.	1	1	1	1/7	1	1	1	1	1	1	1	1
TPM	1	1	1	1/7	1	1	1	1	1	1	1	1

Tablica 14.22. Matrica usporedbe alternativa prema potkriteriju 8. a)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1/5	1	1	1	1	1	1	1	1
Jidoka	1	1	1	1/5	1	1	1	1	1	1	1	1
JIT	1	1	1	1/5	1	1	1	1	1	1	1	1
Kaizen	5	5	5	1	5	5	5	5	5	5	5	5
Kanban	1	1	1	1/5	1	1	1	1	1	1	1	1
Kont. tok	1	1	1	1/5	1	1	1	1	1	1	1	1
Map. toka vr.	1	1	1	1/5	1	1	1	1	1	1	1	1
Poka Yoke	1	1	1	1/5	1	1	1	1	1	1	1	1
SMED	1	1	1	1/5	1	1	1	1	1	1	1	1
Standard. rad	1	1	1	1/5	1	1	1	1	1	1	1	1
Taktno vr.	1	1	1	1/5	1	1	1	1	1	1	1	1
TPM	1	1	1	1/5	1	1	1	1	1	1	1	1

Tablica 14.23. Matrica usporedbe alternativa prema potkriteriju 8. b)

	5S	Jidoka	JIT	Kaizen	Kanban	Kont. tok	Map. toka vrijednosti	Poka Yoke	SMED	Standard. rad	Taktno vrijeme	TPM
5 S	1	1	1	1/6	1	1	1	1	1	1	1	1
Jidoka	1	1	1	1/6	1	1	1	1	1	1	1	1
JIT	1	1	1	1/6	1	1	1	1	1	1	1	1
Kaizen	6	6	6	1	6	6	6	6	6	6	6	6
Kanban	1	1	1	1/6	1	1	1	1	1	1	1	1
Kont. tok	1	1	1	1/6	1	1	1	1	1	1	1	1
Map. toka vr.	1	1	1	1/6	1	1	1	1	1	1	1	1
Poka Yoke	1	1	1	1/6	1	1	1	1	1	1	1	1
SMED	1	1	1	1/6	1	1	1	1	1	1	1	1
Standard. rad	1	1	1	1/6	1	1	1	1	1	1	1	1
Taktno vr.	1	1	1	1/6	1	1	1	1	1	1	1	1
TPM	1	1	1	1/6	1	1	1	1	1	1	1	1

ŽIVOTOPIS

Miroslav Kovačec rođen je 17. srpnja 1980. godine u Zaboku. Osnovnu školu i srednju elektrotehničku školu završio je u Krapini. Nakon srednje škole, 1998. godine upisuje smjer "Strojarstvo" na Fakultetu strojarstva i brodogradnje u Zagrebu. Diplomira u svibnju 2003. godine na usmjeranju konstrukcijskog smjera *Motori i vozila* i stječe zvanje diplomiranog inženjera strojarstva. Od Sveučilišta u Zagrebu na Fakultetu strojarstva i brodogradnje u svibnju 2003. godine dodjeljuje mu se Medalja za izvanredan uspjeh u studiju.

Sredinom 2003. godine zapošljava se u Tvornici stakla Vetropack Straža d.d. u Humu na Sutli na radnom mjestu Tehnolog razvojnog tima. Obavlja poslove vezane uz razvoj, praćenje i analizu rezultata u proizvodnji staklene ambalaže. Aktivno sudjeluje na projektima optimiranja automatske regulacije hlađenja kalupa boca, automatske regulacije mase staklene kapi te popravku alata za proizvodnju staklene ambalaže s pomoću numerički upravljanih strojeva (e. *ComputerNumericalControl – CNC*) i dr.

Akademске godine 2007. / 2008. upisuje poslijediplomski studij strojarstva na Fakultetu strojarstva i brodogradnje, smjer *Industrijsko inženjerstvo i menadžment*.

Početkom 2012. godine zapošljava se u HEP ESCO-u na radnom mjestu Rukovoditelj službe za upravljanje i mjerenja. Obavlja poslove vezane uz implementaciju sustava daljinskog očitavanja energenata i vode na većem broju poslovnih zgrada. Aktivno sudjeluje na međunarodnom projektu "Pametne urbane usluge za povećanje energetske učinkovitosti" (e. *Smart Urban Services for Higher eNergy Efficiency – SUNSHINE*). Područja kojima se bavi jesu i energetski pregledi i energetsko certificiranje zgrada sa složenim tehničkim sustavima, kao i termografska snimanja.

Kao autor ili koautor objavio je nekoliko znanstvenih i stručnih radova u časopisima s međunarodnim recenzijama te na međunarodnim znanstvenim konferencijama. Služi se engleskim jezikom.

BIOGRAPHY

Miroslav Kovačec was born on July 17, 1980 in Zabok. Elementary and secondary school for electrical technician he finished in Krapina. After finishing secondary school in 1988 he started study at Faculty of Mechanical Engineering and Naval Architecture in Zagreb, field construction. He graduated in May 2003, field of specialization Engines and vehicles and acquired the title of graduate mechanical engineers. The University of Zagreb - Faculty of Mechanical Engineering and Naval architecture in May 2003 awarded him with the Medal for outstanding achievement in the study.

Mid 2003 he started working in a glass factory Vetropack Straža in Hum na Sutli as the technologist of the development team. He performs tasks related to the development, monitoring and analysis of the results in the production of glass containers. He actively participated in the projects of optimization of automatic control of cooling the bottle moulds, automatic regulation of mass glass drops and repair tools for production of glass containers using numerically controlled machines (e. Computer Numerical Control – CNC).

In the academic year 2007/2008, he started the postgraduate study of mechanical engineering at the Faculty of Mechanical Engineering and Naval architecture, field Industrial Engineering and Management.

In early 2012 he started to work at HEP ESCO as the Head of Control and Measurement Unit. His main duties are related to the implementation of remote readings of energy and water in a large number of business buildings. He actively participates in the international project Smart Urban Services for Higher Energy Efficiency- SUNSHINE. He actively works in the area of the energy certification of residential and non-residential buildings with simple and complex technical system as well as in the thermographic recording.

He has published several scientific and professional papers as an author or co-author in the journals with the international review and at international scientific conferences. He speaks English.